

Lehrstuhl für
Unternehmenslogistik
Univ.-Prof. Dr. habil. M. Henke

Fakultät Maschinenbau

Technische Universität Dortmund

Referenzmodell einer Data Pipeline zur kausal-prädiktiven Instandhaltung in der Produktion - am Beispiel eines Automobilpresswerks

Zur Erlangung des akademischen Grades eines

Dr.-Ing.

von der Fakultät Maschinenbau

der Technischen Universität Dortmund

genehmigte Dissertation

Safa Evirgen, M.Sc.

aus

Castrop-Rauxel

Tag der mündlichen Prüfung: 24.06.2026

1. Gutachter: Prof. Dr. Michael Henke

2. Gutachter: Prof. Dr. Fazel Ansari

Betreuerin: Prof. Dr. Maylin Wartenberg

Dortmund, 2026

Ergebnisse, Meinungen und Schlüsse dieser Dissertation sind nicht notwendigerweise die der Volkswagen Aktiengesellschaft.

The results, opinions and conclusions expressed in this thesis are not necessarily those of Volkswagen Aktiengesellschaft.

Danksagung

Die vorliegende Arbeit entstand im Rahmen einer kooperativen Promotion zwischen der Technischen Universität Dortmund und der Volkswagen AG während meiner Tätigkeit als Doktorand und Mitarbeiter des Unternehmens. Die Promotionszeit war geprägt von fachlichen Herausforderungen und persönlichen Höhen und Tiefen, zugleich jedoch von der beständigen Neugier, wissenschaftliche Erkenntnisse in die industrielle Praxis zu überführen. Der erfolgreiche Abschluss dieser Arbeit wäre ohne die Begleitung, Unterstützung und Ermutigung zahlreicher Menschen nicht möglich gewesen. Ihnen allen gilt mein aufrichtiger Dank.

Mein besonderer Dank gilt meinem Doktorvater, Herrn **Prof. Dr. habil. Dr. h.c. Michael Henke**, Institutsleiter des Fraunhofer-Instituts für Materialfluss und Logistik (IML) sowie Inhaber des Lehrstuhls für Unternehmenslogistik (LFO) an der Technischen Universität Dortmund, der die Hauptbetreuung dieser Arbeit übernommen und den Promotionsprozess mit großem Engagement begleitet hat. Seine strategische Orientierung, seine wissenschaftliche Weitsicht sowie sein Vertrauen in die eigenständige Ausgestaltung des Forschungsvorhabens haben diese Dissertation maßgeblich geprägt. Ebenso gilt mein ausdrücklicher Dank Frau **Prof. Dr. Maylin Wartenberg**, Professorin für Wirtschaftsinformatik und Data Science an der Hochschule Hannover, für ihre sehr fördernde und stets nahe Betreuung. Ihre fachliche Expertise im Bereich Data Science sowie die kritische Reflexion methodischer Fragestellungen haben wesentlich zur wissenschaftlichen Fundierung dieser Arbeit beigetragen. Darüber hinaus durfte ich während der Promotionszeit gemeinsam mit ihr mehrere studentische Projekte begleiten, die mich sowohl fachlich als auch im Hinblick auf wissenschaftliche Arbeitsweise und Führungsverantwortung nachhaltig geprägt haben. Mein besonderer Dank gilt Herrn **Prof. Dr.-Ing. habil. Fazel Ansari**, Leiter des Forschungsbereichs Produktions- und Instandhaltungsmanagement sowie Universitätsprofessor für datengetriebenes Instandhaltungsmanagement und Leiter Strategische Projekte der Fraunhofer Austria Research GmbH, der zu einem späteren Zeitpunkt in das Betreuungsteam eingetreten ist. Für seine Bereitschaft, die wissenschaftliche Begleitung meiner Arbeit zu übernehmen, sowie für die fundierte fachliche Reflexion und die wertvollen Impulse aus seiner ausgewiesenen Expertise im Bereich der präskriptiven Instandhaltung bin ich ihm in besonderer Weise dankbar.

Ebenso gilt darüber hinaus mein Dank meinen Führungskräften sowie meinen Kolleginnen und Kollegen im Unternehmen für das entgegengebrachte Vertrauen, die fachliche Unterstützung und den offenen Austausch während der gesamten Promotionszeit. Die Möglichkeit, wissenschaftliche Fragestellungen im industriellen Kontext zu diskutieren und kritisch zu reflektieren, hat wesentlich zur praxisnahen Ausgestaltung dieser Arbeit beigetragen. Ebenso danke ich allen Experten, die im Rahmen der Interviews ihre Zeit, ihre Erfahrungen und ihre fachliche Perspektive eingebracht haben. Ihre Bereitschaft zum offenen Dialog und zur kritischen Diskussion war von zentraler Bedeutung für die empirische Fundierung und Weiterentwicklung des Forschungsvorhabens. Da viele Personen in unterschiedlicher Weise zum Erfolg dieser Dissertation beigetragen haben, kann an

dieser Stelle nur stellvertretend gedankt werden. Meine Wertschätzung gilt jeder einzelnen Unterstützung gleichermaßen.

Ein besonderer Dank gilt meinen Freunden, die mich während der gesamten Promotionszeit begleitet haben. **Ahmed Khechen** hat diesen Weg von Beginn an mit mir geteilt. Wir sind gemeinsam in die Promotion gestartet, haben uns gegenseitig unterstützt, die Höhen und Tiefen des jeweils anderen miterlebt und uns immer wieder motiviert, den eingeschlagenen Weg konsequent weiterzugehen. Diese gegenseitige Verbundenheit und der stetige Austausch waren für mich von unschätzbarem Wert. **Kamar Aden Omar** und **Serife Basbayandur** danke ich herzlich für die Zeit und Sorgfalt, mit der sie meine Arbeit Korrektur gelesen und durch ihre Hinweise und Anmerkungen wesentlich zur sprachlichen und inhaltlichen Präzisierung beigetragen haben. **Ersin Uçan**, **Sven Zenker** und **Abdullah Cantürk** danke ich für ihre mentale Unterstützung und die wertvollen Ausgleichsmomente, die es mir ermöglichten, zeitweise Abstand vom Promotionsvorhaben zu gewinnen und mit neuer Kraft und Energie weiterzuarbeiten.

Aile, yorucu yollarda yorgun düştüğümüzde bize ilham veren bir ışıktır. Işığınız hiç solmasın.

Familie bedeutet Rückhalt, Orientierung und Kraft, insbesondere auf langen und herausfordernden Wegen. In Momenten der Erschöpfung schenkt sie Zuversicht, in Phasen des Zweifels Vertrauen und in Zeiten der Anstrengung neue Energie. Dieser beständige Rückhalt war auch während meiner Promotionszeit von besonderem Wert. Von Herzen danke ich meinem Vater **Ibrahim**, meiner Mutter **Zehra** und meiner Schwester **Merve**, die mir in allen Phasen dieser Promotion eine unverzichtbare Stütze waren. Euer Vertrauen, eure Geduld und eure beständige Ermutigung haben mir die notwendige Kraft gegeben, auch in herausfordernden Zeiten meinen Weg konsequent weiterzugehen. Meinem Großvater **Ramazan** und meiner Großmutter **Bahire** gilt mein besonderer Dank für ihren Mut und ihre Entschlossenheit, als Gastarbeiter in ein fremdes Land zu gehen und damit die Grundlage für nachfolgende Generationen zu schaffen. Dass ich heute diesen akademischen Weg beschreiten durfte, ist auch ihrem Einsatz und ihren Entbehrungen zu verdanken. Mein tief empfundener Dank gilt abschließend meiner Ehefrau **Faten**. In Zeiten des Zweifels, in herausfordernden Phasen und ebenso in Momenten der Zuversicht stand sie stets an meiner Seite. Mit Geduld, Verständnis und unermüdlichem Rückhalt hat sie mir den Rücken freigehalten und mir den notwendigen Freiraum gegeben, mich auf die Promotion zu konzentrieren. Dass diese intensive Zeit auch für sie mit Verzicht verbunden war, ist mir sehr bewusst und erfüllt mich mit großer Dankbarkeit. Die Geburt unserer Tochter **Rana** hat diesem Lebensabschnitt eine neue, tiefere Bedeutung verliehen. Sie war für mich eine zusätzliche Motivation, diesen Weg entschlossen zu Ende zu gehen und zugleich Ansporn, ihr ein Vorbild zu sein, das Zielstrebigkeit, Ausdauer und Verantwortungsbewusstsein lebt.

Kurzfassung

Die zunehmende Digitalisierung industrieller Produktionssysteme führt zu einer stetig wachsenden Verfügbarkeit von Prozess-, Zustands- und Kontextdaten. Während datengetriebene Verfahren im Bereich des Condition Monitoring und der Predictive Maintenance bereits breit untersucht sind, besteht weiterhin eine konzeptionelle Lücke zwischen der rein prädiktiven Analyse und einer tatsächlich präskriptiven Entscheidungsunterstützung. Insbesondere fehlt ein strukturierender Bezugsrahmen, der datenanalytische Methoden, kausale Zusammenhänge und operative Entscheidungslogiken systematisch integriert.

Vor diesem Hintergrund verfolgt die vorliegende Dissertation das Ziel, ein wissenschaftlich fundiertes Referenzmodell zu entwickeln, das die konzeptionellen und architektonischen Voraussetzungen für präskriptive Instandhaltungsstrategien schafft, ohne selbst eine vollständige präskriptive Entscheidungsautomatisierung zu beanspruchen. Der Fokus liegt auf einem kausal-prädiktiven Ansatz, der über reine Zustands- oder Ausfallprognosen hinausgeht, indem er datengetriebene Mustererkennung mit strukturierter Ursachenanalyse und kontextbezogener Interpretation verbindet.

Methodisch basiert die Arbeit auf dem Design-Science-Research-Ansatz. In einem iterativen Forschungsprozess wurden zunächst theoriegeleitet Anforderungen aus Literatur und Praxis abgeleitet. Darauf aufbauend wurde ein mehrschichtiges Referenzmodell konzipiert, das funktionale, datenbezogene und infrastrukturelle Ebenen integriert und die Einbettung von Data-Mining-Methoden in industrielle Produktionsumgebungen systematisiert. Zentrales Gestaltungsprinzip ist dabei die strukturierte Kopplung von Prognosemodellen mit kausalen Analysemechanismen, um belastbare Entscheidungsgrundlagen zu erzeugen.

Die prototypische Implementierung demonstriert die technische Umsetzbarkeit des Referenzmodells sowie dessen Übertragbarkeit auf industrielle Anwendungsszenarien. Die Evaluation erfolgt anhand eines systematischen Anforderungsabgleichs, einer vergleichenden Einordnung gegenüber bestehenden Ansätzen sowie durch leitfadengestützte Experteninterviews mit Fachvertretern aus den industriellen Bereichen der Instandhaltung und IT. Die qualitative Expertenevaluation dient dabei der Validierung der strukturellen Vollständigkeit, der praktischen Relevanz und der Anwendbarkeit der entwickelten Architektur.

Die Ergebnisse zeigen, dass das entwickelte Referenzmodell eine konsistente Integrationsarchitektur bereitstellt, die prädiktive Analysen in kausal interpretierbare Zusammenhänge überführt und damit die methodische Grundlage für weiterführende präskriptive Entscheidungslogiken schafft. Durch die systematische Strukturierung des Zusammenspiels von datengetriebener Modellierung, kausaler Analyse und entscheidungsorientierten Abstraktionsebenen trägt das Modell dazu bei, die konzeptionelle Lücke zwischen prädiktiver Instandhaltungsanalyse und handlungsorientierter präskriptiver Strategie systematisch zu reduzieren.

Abstract

The increasing digitalization of industrial production systems has led to a continuously growing availability of process, condition, and contextual data. While data-driven approaches in condition monitoring and predictive maintenance have been extensively studied, a conceptual gap remains between predictive analytics and truly prescriptive decision support. In particular, there is a lack of an integrative reference framework that systematically connects data-analytical methods, causal reasoning, and operational decision logic.

Against this background, this dissertation aims to develop a scientifically grounded reference model that establishes the conceptual and architectural foundations for prescriptive maintenance strategies without claiming full prescriptive decision automation. The focus lies on a causal-predictive approach that extends beyond pure condition or failure forecasting by systematically linking data-driven pattern recognition with structured root-cause analysis and contextual interpretation.

Methodologically, the research follows the Design Science Research paradigm. Within an iterative research process, requirements were derived from both literature and practice and translated into the construction of a multi-layered reference model integrating functional, data-related, and infrastructural perspectives. A central design principle is the structured coupling of predictive models with causal analysis mechanisms in order to generate robust decision-relevant insights and to prepare the systematic transition from predictive results to prescriptive decision logic.

The prototype implementation demonstrates the technical feasibility of the reference model and illustrates its transferability to industrial application scenarios. The evaluation is conducted through a structured requirement-based assessment, a comparative positioning against existing approaches, and semi-structured expert interviews with domain specialists from the industrial maintenance and IT environment. The expert evaluation provides qualitative validation regarding relevance, applicability, and structural completeness of the proposed architecture.

The results indicate that the developed reference model provides a coherent integration architecture that transforms predictive analytics into causally interpretable insights and thereby establishes the methodological foundation for advanced prescriptive decision support mechanisms. By systematically structuring the interplay between data-driven modeling, causal reasoning, and decision-oriented abstraction layers, the model contributes to reducing the conceptual gap between predictive maintenance analytics and actionable prescriptive maintenance strategies in industrial production systems.

Inhaltsverzeichnis

Tabellenverzeichnis	VIII
Abbildungsverzeichnis	IX
Abkürzungsverzeichnis	XI
1 Einleitung und Forschungsmotivation	1
1.1 Ausgangssituation und Motivation	1
1.2 Zielsetzung und Vorgehensweise	2
1.3 Aufbau der Arbeit	4
2 Forschungsansatz und methodische Vorgehensweise	7
2.1 Anforderungen an den Forschungsansatz	7
2.2 Grundlagen des Design Science Research	8
2.3 Leitlinien für die Anwendung von Design Science Research	9
2.3.1 Prinzipien und Ordnungsrahmen nach <i>Hevner et al. (2004)</i>	10
2.3.2 DSR-Methodologie nach <i>Peppers et al. (2007)</i>	11
2.3.3 Fortführende DSR-Empfehlungen nach <i>van Aken et al. (2016)</i>	12
2.3.4 Zwischenfazit: DSR als geeigneter Forschungsansatz für diese Arbeit	13
2.4 Forschungsansatz dieser Arbeit	14
2.5 Methodische Vorgehensweise	15
2.5.1 Systematische Literaturrecherche nach <i>vom Brocke et al. (2009)</i> . . .	16
2.5.2 Eingebettete Multifallstudie nach <i>Yin (2014)</i>	17
2.5.3 Semistrukturiertes Experteninterview nach <i>Lamnek (2016)</i>	20
3 Theoretische Grundlagen	25
3.1 Instandhaltung	25
3.1.1 Begriffe der Instandhaltung	25
3.1.2 Instandhaltungsziele und -strategien	26
3.1.3 Instandhaltung in der Produktion	27
3.2 Anlagendokumentation	30
3.3 Grundlagen der Datenanalyse	32
3.3.1 Data Science und Data Mining	32
3.3.2 Grundlagen der Künstlichen Intelligenz	35
3.3.3 Algorithmische Grundlagen des Machine und Deep Learning	37
3.4 Grundlagen der Data Pipeline in der Produktion	41
3.4.1 Big Data und Smart Data in der Produktion	41
3.4.2 Data Pipeline - Definition und strategische Ansätze	42
3.5 Einordnung der theoretischen Grundlagen	43
4 Forschungsstand zur datengetriebenen Instandhaltung	45
4.1 Systematische Literaturanalyse	45
4.1.1 Rahmen und Umfang der Arbeit	45
4.1.2 Konzeptualisierung des Themas	46

4.1.3	Literaturrecherche und Identifikation relevanter Autoren	47
4.1.4	Forschungsbasierte Literaturanalyse und Forschungsbedarf	48
4.1.5	Systematische Abgrenzung bestehender Arbeiten	56
4.2	Herleitung der Forschungsfragen	68
5	Entwicklung eines Referenzmodells	73
5.1	Gesamtübersicht des Referenzmodells	74
5.2	RME 1 - Datenakquise	76
5.3	RME 2 - Vorverarbeitung und Bereitstellung	80
5.4	RME 3 - Informationsintegration	82
5.5	RME 4 - Analyse	86
5.6	RME 5 - Überwachung	88
5.7	RME 6 - Entscheidungsunterstützung	92
5.8	RME 7 - Modellierung	93
5.9	Zwischenfazit	97
6	Demonstration des Referenzmodells	101
6.1	Strukturierung der Fallstudien	101
6.2	Systematische Bestandsaufnahme der Produktionsdomäne	104
6.2.1	Das Presswerk als betrachtete Produktionsdomäne	104
6.2.2	Instandhaltungsorganisation	105
6.2.3	Technische Infrastruktur	109
6.2.4	Datenerfassung mittels Sensorik	111
6.2.5	Anlagenerfassungssysteme	114
6.2.6	Zwischenfazit der systematischen Bestandsaufnahme	116
6.3	Integration des Referenzmodells	118
6.3.1	Theoretische Einbettung in die bestehende Infrastruktur	119
6.3.2	Technische Implementierung	121
6.3.3	Zwischenfazit der Integration des Referenzmodells	131
6.4	Datenanalytische Anwendungsfälle	133
6.4.1	Ziehkissen	134
6.4.2	Zahnstangenantrieb	147
6.4.3	Druckluftgreifer	161
6.4.4	Gesamtauswertung und Fazit der Data-Mining-Anwendungen	182
6.5	Systematischer Anforderungsabgleich	185
7	Evaluation	189
7.1	Expertenauswahl und Herleitung des Interviewleitfadens	189
7.2	Ergebnisauswertung der Experteninterviews	192
7.2.1	Nützlichkeit	193
7.2.2	Verständlichkeit und Zugänglichkeit	195
7.2.3	Anwendbarkeit und Reproduzierbarkeit	196
7.2.4	Übertragbarkeit und Skalierbarkeit	198
7.2.5	Akzeptanz	201

7.2.6	Querschnittliche Muster und Deutungszusammenhänge	202
7.3	Anforderungsabgleich auf Basis der Evaluation	205
8	Zusammenfassung, kritische Würdigung und Ausblick	209
8.1	Zusammenfassung der Forschungsergebnisse	209
8.2	Kritische Würdigung und weiterer Forschungsbedarf	219
	Literaturverzeichnis	223
A	Algorithmische Grundlagen	279
B	Suchalgorithmus	284
C	Konzeptmatrix der relevanten Autoren	286
D	Im Rahmen der Forschung entstandene Arbeiten	294
E	Kommunikationskette intelligenten Data Pipeline	295
F	Fallstudie Druckluftgreifer	297
G	Interviewleitfaden für die Experteninterviews	299

Tabellenverzeichnis

1	Leitfrage und Forschungsfragen der Arbeit	3
2	DSR-Prinzipien	10
3	Vereinfachte Transkriptionsregeln in Anlehnung an Kuckartz	23
4	Schlagwortsuche für die Literaturrecherche	48
5	Abgrenzungsmatrix der betrachteten Arbeiten	59
6	Zuordnung der Forschungsfragen zu den Kapiteln der Dissertation	71
7	Merkmale eines Referenzmodells	73
8	Vergleich von Labeling-Methoden	85
9	Anforderungsmatrix an das Referenzmodell	100
10	Übersicht Sensorsignale Ziehkissen-Fallstudie	137
11	Übersicht Sensorsignale Zahnstangen-Fallstudie	150
12	Übersicht Sensorsignale Druckluftgreifer-Fallstudie	166
13	Supervised Learning – Genauigkeitswerte der Klassifikatoren	176
14	Systematischer Abgleich der Anforderungen mit dem Umsetzungsstand	187
15	Übersicht der interviewten Experten	191
16	Rückspiegelung der Evaluation auf den systematischen Anforderungsabgleich	206
17	Übersicht wichtiger Leistungsmetriken	279
18	Überblick über ausgewählte Supervised Learning Modelle	280
18	Überblick über ausgewählte Supervised Learning Modelle	281
18	Überblick über ausgewählte Supervised Learning Modelle	282
19	Beispiele für Modellparameter ausgewählter Verfahren	283
20	Übersicht der Autoren und ihrer Beiträge	286
20	Übersicht der Autoren und ihrer Beiträge	287
20	Übersicht der Autoren und ihrer Beiträge	288
21	Konzeptmatrix der relevanten Autoren	289
21	Konzeptmatrix der relevanten Autoren	290
21	Konzeptmatrix der relevanten Autoren	291
21	Konzeptmatrix der relevanten Autoren	292
21	Konzeptmatrix der relevanten Autoren	293
22	Im Rahmen der Forschung entstandenen Arbeiten	294
23	Interviewleitfaden für die semistrukturierten Experteninterviews	299

Abbildungsverzeichnis

1	Aufbau der Arbeit	6
2	Prozessmodell der DSR-Methodologie	12
3	Forschungsdesign dieser Arbeit	14
4	Literature Review Ansatz	16
5	Fallstudiendesigntypen	19
6	Ablaufmodell des Experteninterviews	21
7	Evolution der Instandhaltung	28
8	Ablaufplan für wissensgetriebene Projekte	34
9	Taxonomie der Literaturrecherche für die vorliegende Arbeit	46
10	Konzept-Map für die Literaturrecherche	47
11	Konzeptmatrix der relevanten Autoren im Forschungsthema	56
12	Referenzmodell der intelligenten Data Pipeline	75
13	Vorverarbeitung Sensordaten und Textdaten	81
14	Fallstudiendesign der vorliegenden Arbeit	103
15	Schaubild Transferpressenlinie	105
16	Arbeitsablaufdiagramm geplante Instandhaltung	108
17	Arbeitsablaufdiagramm ungeplante Instandhaltung	109
18	Bestandsaufnahme der bestehenden IT-Architektur im Presswerk	112
19	Einbettung des Referenzmodells in die bestehende Infrastruktur	120
20	Konzeptionelle Darstellung der Kommunikationskette	125
21	Technisch realisierte Implementierung des Referenzmodells	127
22	Schematische Anordnung Verdrängerzylinder	135
23	Kenngößen des Regelungsverhaltens eines Ziehkissens	136
24	Exemplarische Druckverläufe der Verdränger	137
25	Festgelegte Kurvenbereiche des Verdrängerdrucks	138
26	Abweichung der Druckverläufe vom Mittelwert über mehrere Zyklen	140
27	Exemplarische Konfusionsmatrix für 1000 Zyklen	142
28	Exemplarische Zustandsaussage für Verdränger 1	144
29	Schematische Darstellung Modellierung und Bereitstellung	144
30	Dashboard zur modellbasierten Zustandsüberwachung	145
31	Chronologie Schaden Pressenlinie	146
32	Schematischer Aufbau Transfersystem	148
33	Eingebaute Zahnstangendefekte	149
34	Exemplarischer Signalverlauf Transfer	150
35	Auswirkungen auf die Sensorsignale durch Verschleiß	151
36	Auswirkungen auf die Sensorsignale durch Zahnbruch	153
37	Merkmalsextraktion Sensorsignale X1-Antrieb	153
38	Segmentierung der Kurvenverläufe X1-Antrieb	154
39	Konfusionsmatrizen MLP	155
40	Regelverhalten X1-Antrieb	157
41	Modellierung LSTM auf Basis Reglerverhalten	158
42	Schaubild Modellierungsschritte LSTM und 1D-CNN	159

43	Konfusionsmatrix 1D-CNN	160
44	Prinzip der Drucklufterzeugung	162
45	Bewegungsablauf Transfer	164
46	Sensorplan Pressenlinie	164
47	Ausschnitt bereinigter Datensatz	167
48	Ausgabe ersten 3000 Datenpunkte	168
49	Ausreißeranalyse mittels 3σ -Methode	169
50	IQR-Ausreißeranalyse des Druckluftverbrauchs	170
51	Transformation der Zeitreihendaten in Pressenzyklen	171
52	Feature Extraction	172
53	Ausgewählte Merkmale	172
54	Konfusionsmatrix der MMD-Auswertung	175
55	Konfusionsmatrix k-Means	178
56	Anzahl der mit k-Means erkannten Anomalien über die Anzahl Hübe	180
57	Anzahl der mit MMD erkannten Anomalien über die Anzahl Hübe.	181
58	Kommunikationsaufbau X-Tools	295
59	Topics für die Fallstudie Ziehkissen	295
60	Beispiel publizierte Datennachricht Ziehkissen	296
61	Applikationen Industrial Edge Management System	296
62	Ausgabepaket des Ziehkissen-Modells	296
63	Vergleich: 3σ - und IQR-Ausreißeranalyse für alle Luftverbrauchssensoren	297
64	Mittlerer Luftverbrauch je Sensor über Pressenposition	298

Abkürzungsverzeichnis

AV	Abnutzungsvariante
BDE	Betriebsdatenerfassung
CIMO	Context, Intervention, Mechanism, Outcome
CMS	Condition Monitoring System
CRISP-DM	Cross Industry Standard Process for Data Mining
DSR	Design Science Research
DT	Decision Tree
ELT	Extract Load Transform
ERP	Enterprise Resource Planning
ETL	Extract Transform Load
FF	Forschungsfrage
FN	Falsch Negative
FP	Falsch Positive
HDD	Hard-Disk-Drive
HITL	Human-in-the-Loop
HTTPS	Hypertext Transfer Protocol Secure
IPC	Industrie-PC
KDD	Knowledge Discovery in Databases
k-NN	K-Nearest Neighbors
KPI	Key Performance Indicator
LDA	Linear Discriminant Analysis
LF	Leitforschungsfrage
LR	Logistic Regression
MAE	Mean Absolute Error
MLOps	Machine Learning Operations
MMD	Maximum Mean Discrepancy
MQTT	Message Queuing Telemetry Transport
MSE	Mean Squared Error
NB	Naive Bayes
NLP	Natural Language Processing
OPCUA	Open Platform Communications Unified Architecture
OT	operational technology
RBF	Radial Basis Function
S3	simple storage service
SGD	Stochastic Gradient Descent
SQL	Structured Query Language
SPS	Speicherprogrammierbare Steuerung
SVM	Support Vector Machine
TN	Wahre Negative
TP	Wahre Positive
ZB	Zahnbruch

1 Einleitung und Forschungsmotivation

Das erste Kapitel dient der thematischen Herleitung des Betrachtungsgegenstands der vorliegenden Arbeit. In **Kapitel 1.1** werden die Ausgangssituation und die zugrunde liegende Motivation dargestellt. Darauf aufbauend erfolgt in **Kapitel 1.2** die Formulierung der Zielsetzung sowie die Beschreibung des methodischen Vorgehens. **Kapitel 1.3** schließt mit der Darstellung des Aufbaus der Arbeit und der damit verbundenen Strukturierung ab.

1.1 Ausgangssituation und Motivation

Der zunehmende Wettbewerbsdruck zwingt produzierende Unternehmen dazu, ihre Produktions- und Instandhaltungsprozesse konsequent nach Wirtschaftlichkeits- und Effizienzkriterien auszurichten [vgl. Hofer et al. 2020, S.559–560; Rauber und Georg 2021, S.15]. In diesem Kontext stellt eine hohe Anlagenverfügbarkeit einen zentralen Erfolgsfaktor dar, da ungeplante Stillstände unmittelbar zu Produktionsausfällen führen und erhebliche direkte sowie indirekte Kosten verursachen [vgl. Prasad Nepal und Park 2004, S.199–201]. Zur Sicherstellung der Anlagenverfügbarkeit haben sich im industriellen Umfeld unterschiedliche Instandhaltungsstrategien etabliert, die sich hinsichtlich ihres technologischen Reifegrads, ihrer Entscheidungslogik und ihres Beitrags zur Gesamtanlageneffektivität deutlich unterscheiden [vgl. Choubey et al. 2020, S.1–2].

Während reaktive Instandhaltung (*run to failure*) ausschließlich im Störfall eingreift und mit hohen ungeplanten Ausfallkosten verbunden ist, verfolgt präventive Instandhaltung einen zeit- oder nutzungsbasierten Ansatz mit festen Wartungsintervallen [vgl. Choubey et al. 2020, S.202; Kropik 2021, S.328–329; Mühlnickel et al. 2018, S.354]. Obwohl hierdurch ungeplante Stillstände reduziert werden können, führt dieser Ansatz häufig zu ineffizienten und nicht bedarfsgerechten Wartungsmaßnahmen. Prädiktive Instandhaltung erweitert diesen Ansatz um datengetriebene Prognosemodelle, die auf kontinuierlicher Zustandsüberwachung basieren und potenzielle Ausfälle frühzeitig erkennen sollen [vgl. Bink und Zschech 2018, S.553–555]. Als konzeptionelle Weiterentwicklung wird in der Literatur die präskriptive Instandhaltung diskutiert, die über reine Vorhersagen hinausgeht und Entscheidungen oder Handlungsempfehlungen systematisch unterstützt [vgl. Consilvio et al. 2019, S.1–2].

Die Umsetzung sowohl prädiktiver als auch präskriptiver Instandhaltungsansätze setzt den Aufbau leistungsfähiger Daten- und Analyseinfrastrukturen voraus, die eine durchgängige Verarbeitung, Integration und Interpretation industrieller Prozess- und Zustandsdaten ermöglichen [vgl. Spexet et al. 2023, S.6]. Neben technischen Grundlagen wie Sensorik, Datenintegration und skalierbaren Architekturen sind hierfür insbesondere Methoden des Data Mining sowie Mechanismen zur systematischen Nutzung von Domänenwissen erforderlich [vgl. Smit und Lamprecht 2023, S.8–10]. Zahlreiche Studien zeigen jedoch, dass die bloße Verfügbarkeit großer Datenmengen nicht ausreicht, um belastbare und handlungsrelevante Erkenntnisse zu gewinnen. So verdeutlichen *Afroze et al. (2024)* anhand einer systematischen Analyse von 50 Anwendungsfällen, dass Predictive-Maintenance-Modelle erst durch die gezielte Einbindung domänenspezifischen Wissens in unterschiedlichen Phasen des Analyseprozesses, wie etwa bei der Datenaufbereitung, der Merkmalsbildung oder

der Ergebnisinterpretation, ihre volle Aussagekraft entfalten. Das zugrunde liegende Konzept des *Informed Machine Learning framework* adressiert genau diesen Bedarf, indem datengetriebene Modelle um explizites Fach- und Prozesswissen ergänzt werden, um Interpretierbarkeit und Praxistauglichkeit zu erhöhen [vgl. Afroze et al. 2024, S.76–78]. Ergänzend zeigen Klein (2025) sowie Menon und Tuladhar (2024), dass fehlende Erklärbarkeit, begrenzte Skalierbarkeit und unzureichende Wissensintegration zentrale Gründe dafür sind, warum viele datengetriebene Instandhaltungsansätze in der industriellen Praxis hinter ihren Erwartungen zurückbleiben. Insbesondere auf Systemebene stoßen bestehende Verfahren an ihre Grenzen, da ihnen eine strukturierte Verknüpfung von Sensordaten, Prozesswissen und Entscheidungslogiken fehlt. Auch Miller und Dubrawski (2020) weisen darauf hin, dass viele Ansätze auf isolierte Komponenten fokussiert bleiben und kausale Zusammenhänge auf Systemebene nicht hinreichend abbilden.

Vor diesem Hintergrund zeigt sich ein klarer Bedarf an einem übergreifenden Referenzmodell, das die systematische Integration heterogener Datenquellen, analytischer Verfahren und domänenspezifischen Wissens in einer intelligenten Data Pipeline strukturiert unterstützt. Ein solches Referenzmodell muss insbesondere in der Lage sein, kausal-prädiktive Zusammenhänge zwischen Prozessparametern, Zuständen und beobachteten Abweichungen transparent abzubilden, um prädiktive Ergebnisse erklärbar, kontextualisiert und anschlussfähig für weiterführende Entscheidungsprozesse zu machen.

Die Motivation dieser Arbeit besteht daher darin, ein Referenzmodell einer intelligenten Data Pipeline für Produktionsumgebungen zu entwickeln, das die Anwendung datengetriebener Analyseverfahren systematisch mit domänenspezifischem Wissen verknüpft und so eine kausal fundierte prädiktive Instandhaltung ermöglicht. Auf dieser Grundlage sollen die methodischen, technischen und organisatorischen Voraussetzungen geschaffen werden, um präskriptive Instandhaltungsstrategien schrittweise, nachvollziehbar und verantwortungsvoll weiterzuentwickeln und die Anlagenverfügbarkeit sowie die Gesamtanlageneffektivität nachhaltig zu verbessern.

1.2 Zielsetzung und Vorgehensweise

Eine leistungsfähige Data Pipeline stellt eine zentrale Voraussetzung für datengetriebene Instandhaltungsstrategien dar, da sie den durchgängigen Fluss von Rohdaten bis hin zu analytisch gestützten Entscheidungsgrundlagen sicherstellt [vgl. O'Donovan et al. 2015, S.2–4]. Zu den grundlegenden Funktionselementen zählen die strukturierte Datenaufnahme, die Vorverarbeitung und Transformation heterogener Datenquellen, deren Speicherung in skalierbaren Architekturen sowie die analytische Verarbeitung mittels Data-Mining-Methoden [vgl. Raj et al. 2020, S.17–18]. Ergänzend sind Mechanismen zur Sicherstellung von Datenherkunft, Nachvollziehbarkeit und operativer Einbettung erforderlich, um analytische Ergebnisse im industriellen Kontext nutzbar zu machen [vgl. Oleghe und Salonitis 2020, S.725–726]. Bestehende Data-Pipeline-Konzepte fokussieren jedoch häufig auf technische Aspekte der Datenintegration und -analyse, während die systematische Einbettung von Domänenwissen, die Kontextualisierung analytischer Ergebnisse sowie deren strukturierte Überführung in handlungsrelevante Entscheidungslogiken nur unzureichend berücksichtigt werden [vgl. Orošnjak et al. 2025, S.1–3; Ordieres-Meré et al. 2025, S.4–6;

Mallioris, Aivazidou et al. 2024, S.81–84; Siyuan Chen et al. 2025, S.678–679]. Insbesondere fehlt bislang ein übergreifendes Referenzmodell, das die funktionalen, methodischen und wissensbezogenen Komponenten einer intelligenten Data Pipeline konsistent integriert und dabei explizit auf die Unterstützung kausal-prädiktiver Instandhaltungsansätze ausgerichtet ist. Präskriptive Instandhaltung wird in der Literatur zwar als Zielbild adressiert, jedoch häufig ohne eine klare strukturelle Fundierung der hierfür notwendigen Daten-, Wissens- und Entscheidungsarchitektur.

Vor diesem Hintergrund besteht die Zielsetzung dieser Arbeit in der Entwicklung eines Referenzmodells einer intelligenten Data Pipeline für Produktionsumgebungen, das sich in bestehende IT-Infrastrukturen integrieren lässt und kausal-prädiktive Instandhaltungsansätze systematisch unterstützt. Ziel ist es dabei nicht, präskriptive Entscheidungen unmittelbar zu automatisieren, sondern die technischen, methodischen und wissensbezogenen Voraussetzungen zu schaffen, auf deren Basis präskriptive Instandhaltungsstrategien schrittweise, nachvollziehbar und verantwortungsvoll weiterentwickelt werden können. Das Referenzmodell adressiert hierzu die funktionalen Ebenen der Datenakquise, der Vorverarbeitung und Bereitstellung, der Informationsintegration, der Modellierung und Analyse, der Überwachung sowie der Entscheidungsunterstützung als zentrale Bausteine einer intelligenten Data Pipeline.

Aus dieser Zielsetzung leiten sich die forschungsleitende Frage (LF) sowie die zugehörigen Forschungsfragen (FF) ab, die den Entwicklungs- und Evaluationsprozess der Arbeit strukturieren. Die Leitfrage fokussiert die Gestaltung des Referenzmodells als übergeordnetes Artefakt, während die Forschungsfragen spezifische technische, methodische und organisatorische Herausforderungen adressieren, die im Rahmen der Entwicklung, Anwendung und Bewertung der intelligenten Data Pipeline identifiziert werden. **Tabelle 1** gibt einen Überblick über die formulierte Leitfrage und die daraus abgeleiteten Forschungsfragen.

Tabelle 1: Leitfrage und Forschungsfragen der Arbeit

LF	Wie ist ein Referenzmodell einer intelligenten Data Pipeline für Produktionsumgebungen zu gestalten, das sich in bestehende IT-Infrastrukturen integrieren lässt und einen kausal-prädiktiven Instandhaltungsansatz als Grundlage für eine präskriptive Instandhaltungsstrategie strukturiert unterstützt?
FF1	Welche Herausforderungen ergeben sich bei der Integration eines Referenzmodells einer intelligenten Data Pipeline für datengetriebene Instandhaltungsstrategien in die bestehende IT-Infrastruktur einer Produktionsumgebung?
FF2	Welche Herausforderungen bestehen bei der Anwendung von Data-Mining-Methoden auf Produktions- und Maschinendaten im Hinblick auf die Gewinnung nutzbarer Informationen für datengetriebene Instandhaltungsstrategien?
FF3	Welche Anforderungen lassen sich an Konzepte ableiten, die Wissen aus technischen Anlagendokumentationen automatisiert mit Sensordaten verknüpfen, um kausal begründete Handlungsempfehlungen abzuleiten?
FF4	Wie kann ein kausal-prädiktiver Instandhaltungsansatz, der durch eine intelligente Data Pipeline unterstützt wird, als Grundlage für präskriptive Instandhaltungsstrategien genutzt werden?

Um den inhaltlichen und methodischen Anforderungen einer wissenschaftlichen Arbeit gerecht zu werden, ist die Wahl eines Forschungsansatzes erforderlich, der den spezifischen

Charakteristika des Anwendungsbereichs entspricht und die Forschungsziele adäquat adressiert [vgl. Grosse 2019, S.2]. Zur Beantwortung der Forschungsfragen und zur Erreichung der Zielsetzung wird der gestaltungsorientierte Forschungsansatz des **Design Science Research (DSR)** gewählt. Der DSR-Ansatz nach *van Aken et al. (2016)*, *Peppers et al. (2007)* und *Hevner (2007)* eignet sich insbesondere für Forschungsvorhaben, bei denen die Entwicklung, Implementierung und Evaluation eines Artefakts im Zentrum steht. Seine Stärke liegt in der systematischen Verknüpfung wissenschaftlicher Rigorosität mit praktischer Relevanz [vgl. van Aken et al. 2016, S.5; A. Hevner und Chatterjee 2010, S.17–18].

Im Rahmen dieser Arbeit wird das Referenzmodell der intelligenten Data Pipeline als zentrales Artefakt des DSR-Prozesses entwickelt. Die Forschung folgt dabei einem iterativen Vorgehen, das die Analyse des Problemraums (Relevanzzyklus), die Gestaltung und Demonstration des Artefakts (Designzyklus) sowie dessen theoretische Fundierung und empirische Evaluation (Strengenzezyklus) systematisch miteinander verknüpft. Auf diese Weise wird sichergestellt, dass das entwickelte Referenzmodell sowohl auf bestehenden wissenschaftlichen Erkenntnissen aufbaut als auch unter realitätsnahen industriellen Bedingungen überprüft wird. Die iterative Vorgehensweise des DSR ermöglicht es zudem, Erkenntnisse aus der praktischen Anwendung, aus Fallstudien sowie aus der Expertenevaluation kontinuierlich in die Weiterentwicklung des Referenzmodells einfließen zu lassen. Damit wird gewährleistet, dass die entwickelte intelligente Data Pipeline nicht als abstraktes Zielbild verbleibt, sondern als anschlussfähiger, entwicklungsfähiger Bezugsrahmen für kausalprädiktive und perspektivisch präskriptive Instandhaltungsstrategien dient. Der gewählte Forschungsansatz bildet somit die methodische Grundlage, um sowohl einen substantiellen wissenschaftlichen Beitrag zu leisten als auch praxisrelevante Gestaltungsempfehlungen für datengetriebene Instandhaltung in Produktionsumgebungen abzuleiten.

1.3 Aufbau der Arbeit

Die vorliegende Arbeit ist entsprechend der in **Abbildung 1** dargestellten Struktur in insgesamt acht Kapitel gegliedert und folgt dem Paradigma des Design Science Research (DSR), das einen systematisch-iterativen Forschungsprozess aus Analyse, Gestaltung, Anwendung und Evaluation vorsieht.

Kapitel 1 führt in das Forschungsthema ein und schafft den konzeptionellen Rahmen der Arbeit. Es beschreibt die Ausgangssituation und Motivation, formuliert die Zielsetzung sowie das methodische Vorgehen und gibt einen Überblick über den Aufbau der Arbeit. Dadurch wird sowohl die inhaltliche Einordnung des Forschungsvorhabens als auch die Nachvollziehbarkeit der gewählten Struktur sichergestellt.

In **Kapitel 2** wird der zugrunde liegende Forschungsansatz detailliert erläutert. Hier erfolgt die methodische Einbettung der Arbeit in den Design-Science-Research-Ansatz. Der konkrete Forschungsprozess wird strukturiert dargestellt und begründet, sodass transparent wird, wie die Entwicklung, Demonstration und Evaluation des Artefakts innerhalb der DSR-Zyklen umgesetzt werden.

Kapitel 3 behandelt die theoretischen und begrifflichen Grundlagen der Arbeit. Es umfasst zentrale Konzepte der Instandhaltung, der Anlagendokumentation, der Datenanalyse sowie der Data-Pipeline-Architekturen in Produktionsumgebungen. Ziel dieses Kapitels ist

es, eine konsistente theoretische Basis zu schaffen und die für die Arbeit relevanten Begriffe, Modelle und Zusammenhänge klar zu definieren.

Der Stand der Forschung wird in **Kapitel 4** systematisch aufgearbeitet. Auf Grundlage einer strukturierten Literaturrecherche werden bestehende Ansätze zur datengetriebenen Instandhaltung, zu Data Pipelines sowie zur Integration von Domänenwissen analysiert und kritisch eingeordnet. Darauf aufbauend wird eine Forschungslücke identifiziert, aus der die forschungsleitende Frage sowie die zugehörigen Forschungsfragen abgeleitet werden, die den weiteren Verlauf der Arbeit strukturieren.

Die Entwicklung des Referenzmodells der intelligenten Data Pipeline erfolgt in **Kapitel 5** theoriegeleitet und anforderungsbasiert. Ausgangspunkt bildet die in den vorhergehenden Kapiteln aufgearbeitete theoretische Fundierung sowie die systematische Analyse des Stands der Forschung. Auf dieser Grundlage wird eine Anforderungsmatrix abgeleitet, die die zentralen funktionalen, strukturellen und konzeptionellen Anforderungen an das Referenzmodell formalisiert. Diese Anforderungsmatrix fungiert als normativer Gestaltungsrahmen für die Modellkonstruktion und stellt zugleich den zentralen Referenzpunkt für die nachfolgenden Demonstrations- und Evaluationsschritte dar.

In **Kapitel 6** wird das entwickelte Referenzmodell exemplarisch angewendet und demonstriert. Dies umfasst sowohl die Integration des Modells in die bestehende IT- und Produktionsinfrastruktur eines Automobilpresswerks als auch die Umsetzung ausgewählter Data-Mining-Fallstudien mit realen und simulationsbasierten Produktionsdaten. Ziel dieses Kapitels ist es, die technische Umsetzbarkeit, Funktionalität und Anschlussfähigkeit des Referenzmodells unter praxisnahen Bedingungen zu überprüfen.

Die Evaluation des entwickelten Artefakts erfolgt in **Kapitel 7**. Hier wird das Referenzmodell anhand definierter Evaluationskriterien systematisch bewertet. Neben der Reflexion der Umsetzungsergebnisse werden qualitative Experteninterviews eingesetzt, um Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Akzeptanz aus Sicht der industriellen Praxis zu beurteilen. Die Evaluation dient damit der fundierten Einschätzung der Artefaktgüte sowie des wissenschaftlichen und praktischen Beitrags der Arbeit.

Abschließend fasst **Kapitel 8** die zentralen Forschungsergebnisse zusammen, ordnet sie in den Kontext der formulierten Forschungsfragen ein und unterzieht sie einer kritischen Würdigung. Darüber hinaus werden Limitationen der Arbeit aufgezeigt und Implikationen für zukünftige Forschung und industrielle Anwendung diskutiert. Der Ausblick skizziert weiterführende Entwicklungs- und Forschungsperspektiven, insbesondere im Hinblick auf die Weiterentwicklung kausal-prädiktiver hin zu präskriptiven Instandhaltungsstrategien auf Basis des vorgestellten Referenzmodells.




Abbildung 1: Aufbau der Arbeit

2 Forschungsansatz und methodische Vorgehensweise

Dieses Kapitel dient der Strukturierung des Forschungsansatzes sowie der Darlegung der methodischen Vorgehensweise der vorliegenden Arbeit. Zunächst werden in Kapitel 2.1 die grundlegenden Anforderungen an den Forschungsansatz beschrieben. Darauf aufbauend werden in Kapitel 2.2 die theoretischen Grundlagen des Design Science Research als übergeordneter Forschungsansatz dieser Arbeit erläutert.

In Kapitel 2.3 werden anschließend die relevanten Leitlinien für die Anwendung des Design Science Research systematisch dargestellt. Auf dieser Basis wird in Kapitel 2.4 der konkrete Forschungsansatz der vorliegenden Arbeit hergeleitet. Abschließend werden in Kapitel 2.5 die eingesetzten Forschungsmethoden erläutert und in den Gesamtkontext des Forschungsdesigns eingeordnet.

2.1 Anforderungen an den Forschungsansatz

Ein klar definierter und konsistent umgesetzter Forschungsansatz ist eine zentrale Voraussetzung für methodisch korrektes wissenschaftliches Arbeiten, da er Leitfragen, theoretische Grundlagen, Datenbasis sowie die daraus abgeleiteten Ergebnisse systematisch strukturiert und miteinander verknüpft [vgl. Grosse 2019, S. 2]. Zugleich trägt er wesentlich zur Transparenz, Nachvollziehbarkeit und Überprüfbarkeit des Forschungsprozesses bei [vgl. Yin 2009, S. 35; Bachhiesl et al. 2018, S. 16]. Die Ausgestaltung des Forschungsansatzes leitet sich dabei aus dem jeweiligen kontextspezifischen Bezugsrahmen, dem Forschungsziel sowie dem bestehenden theoretischen und praktischen Wissensstand ab [vgl. Creswell 2006, S. 16–17].

Das vorliegende Forschungsvorhaben adressiert die Anwendung von Data-Mining-Methoden in einer produktiven industriellen Umgebung. Untersuchungsgegenstand ist das Presswerk eines Automobilherstellers, insbesondere die dort eingesetzten Umformanlagen zur Herstellung von Karosserieteilen [vgl. Kropik 2009, S. 9]. Die Komplexität dieses Anwendungsbereichs ergibt sich aus den hohen Anforderungen an die Anlagenverfügbarkeit sowie aus den technischen Charakteristika der Umformanlagen, wie dem hohen Automatisierungsgrad, dem Einsatz unterschiedlicher Medien und dem energieintensiven Gesamtprozess [vgl. W. Huber 2016, S. 43–44]. Darüber hinaus ist der Mensch als wissens- und erfahrungstragende Komponente integraler Bestandteil dieses soziotechnischen Systems, insbesondere im Kontext Instandhaltungsrelevanter Tätigkeiten.

Ziel der Arbeit ist die Entwicklung eines theoriegeleiteten Referenzmodells einer intelligenten Data Pipeline für die Anwendung von Data-Mining-Methoden in der Produktion. Das Referenzmodell fokussiert primär die Unterstützung kausal-prädiktiver Instandhaltungsstrategien und ist zugleich so ausgelegt, dass es als strukturelle Grundlage für weiterführende präskriptive Ansätze dienen kann. Hierzu werden sowohl bestehende Artefakte aus Forschung und Technik als auch explizites Domänenwissen aus dem industriellen Anwendungskontext herangezogen. Vor dem Hintergrund einer expliziten Forschungsumgebung des Artefakts ist ein rein problemorientierter Ansatz ohne hinreichende Generalisierbarkeit der Lösung zu vermeiden [vgl. van Aken et al. 2016, S. 5; A. Hevner und Chatterjee 2010, S. 17–18]. Stattdessen sind sowohl der praktische Nutzen des entwickelten Artefakts als

auch die wissenschaftliche Rigorosität des Forschungsprozesses sicherzustellen.

Obwohl die Themenfelder Instandhaltung, Data Mining und Data Pipelines sowohl in Forschung als auch Praxis intensiv behandelt werden, fehlt bislang eine integrierte, referenzmodellbasierte Betrachtung, die den gesamten Prozess der Datenbereitstellung und -verarbeitung für kausal-prädiktive Instandhaltungsstrategien in der Produktion systematisch adressiert. Insbesondere die strukturierte Verbindung von Datenpipeline-Architekturen, Data-Mining-Methoden und instandhaltungsrelevanten Anforderungen in einem übertragbaren Referenzmodell stellt weiterhin eine Forschungslücke dar. Eine detaillierte Analyse des Stands von Forschung und Technik erfolgt in Kapitel 4, auf deren Grundlage die Forschungsfragen dieser Arbeit abgeleitet werden.

Vor diesem Hintergrund wird in der vorliegenden Arbeit der **gestaltungsorientierte Forschungsansatz des Design Science Research (DSR)** nach *van Aken et al. (2016)*, *Peppers et al. (2007)* und *Hevner (2007)* verfolgt. Zur Sicherstellung der wissenschaftlichen Nachvollziehbarkeit werden im Folgenden die grundlegenden Prinzipien und Leitlinien des DSR dargestellt und darauf aufbauend der konkrete Forschungsansatz der Arbeit hergeleitet, der die Grundlage für die systematische Generierung neuer Erkenntnisse im betrachteten Forschungsgebiet bildet [vgl. Bachhiesl et al. 2018, S. 16; Mintzberg 1979, S. 16].

2.2 Grundlagen des Design Science Research

Das Design-Science-Paradigma ist wesentlich durch das Verständnis artefaktorientierter Forschung geprägt, dessen theoretische Grundlagen maßgeblich auf *Simon (1969)* und dessen Werk *The Sciences of the Artificial* zurückgehen. Zentrales Element ist die Entwicklung innovativer Artefakte zur Lösung realer, praktischer Problemstellungen [vgl. You und Hands 2019, S.1346–1347]. Der Begriff des **Designs** umfasst dabei sowohl den gestaltungsorientierten Entwicklungsprozess als auch das daraus hervorgehende Artefakt [vgl. Peppers et al. 2007, S.47]. Dieses duale Verständnis bildet das grundlegende Problemlösungsparadigma des Design Science Research (DSR), in dem die analytische Betrachtung iterativ zwischen Gestaltungshandlung und Artefakt wechselt. Entsprechend definieren *van Aken et al. (2016)* das Kernprodukt des DSR als ein systematisch entwickeltes, gut verstandenes und dokumentiertes generisches Design, dessen pragmatische Gültigkeit im Anwendungskontext überprüft wurde [vgl. van Aken et al. 2016, S.3].

Eine zentrale Wissensform im artefaktorientierten Forschungsprozess stellt dabei präskriptives Wissen dar. Dieses beschreibt Wissen über vom Menschen geschaffene Artefakte und deren zweckgerichtete Gestaltung und dient als Bindeglied zwischen theoretischer Erkenntnis und praktischer Anwendung [vgl. Chandra et al. 2015, S.4039; S. Gregor und A. R. Hevner 2013, S.343–344]. Zur Strukturierung und Operationalisierung generischer Designs werden im DSR häufig **Designprinzipien** herangezogen, die abstrahierte, kontextsensitiv anwendbare Gestaltungsaussagen formulieren. Diese können unter anderem entlang der **CIMO**-Logik beschrieben werden, welche die Dimensionen **C**ontext, **I**ntervention, **M**echanism und **O**utcome umfasst und erläutert, wie bestimmte Interventionen in einem gegebenen Kontext über spezifische Wirkmechanismen zu intendierten Ergebnissen führen [vgl. Denyer et al. 2008, S.395–396]. Neben der Entwicklung und Evaluation von Artefakten

können darüber hinaus auch neue empirische Erkenntnisse sowie methodische Innovationen als relevante Ergebnisse des DSR betrachtet werden [vgl. van Aken et al. 2016, S. 4].

Im Gegensatz zu konkreten Systemanforderungen oder detaillierten Implementierungsvorgaben strukturieren Designprinzipien den Lösungsraum, ohne eine deterministische Umsetzung vorzugeben [vgl. van Aken 2014, S.3–4]. Sie übernehmen damit eine zentrale Rolle im DSR, indem sie als vermittelnde Ebene zwischen theoretischen Erkenntnissen und der konkreten Ausgestaltung von Artefakten fungieren und zur Nachvollziehbarkeit sowie Wiederverwendbarkeit gestaltungsorientierter Forschungsergebnisse beitragen [vgl. S. Gregor und A. R. Hevner 2013, S.341].

Zur Einordnung ihres Abstraktionsniveaus lassen sich Designprinzipien als **Theorien mittlerer Reichweite** im Sinne von *Merton (1968)* verstehen [vgl. Merton 1968, S.39]. Diese sind zwischen universellen Theorien mit umfassendem Geltungsanspruch und hochspezifischen Mikrotheorien angesiedelt [vgl. S. Gregor und A. R. Hevner 2013, S.339–340]. Kennzeichnend sind klar formulierte, logisch konsistente und empirisch überprüfbare Aussagen mit ausgeprägter Praxisorientierung [vgl. Ketokivi 2006, S. 217; Gregor 2006, S. 616]. Entsprechend lassen sich Designprinzipien im Sinne von *van Aken (2016)* als generalisierbare, jedoch kontextabhängig zu prüfende Gestaltungsaussagen verstehen, deren Gültigkeit nicht vorausgesetzt, sondern empirisch im Anwendungskontext überprüft wird [vgl. van Aken et al. 2016, S.4].

Das Design-Science-Paradigma findet insbesondere im Forschungsfeld der Informationssysteme (IS) breite Anwendung, dessen gestaltungsorientierter Charakter auf komplexe, kontextabhängige Problemstellungen ausgerichtet ist [vgl. Hevner et al. 2004, S.76; Simon 1996, S.134–137]. Diese Problemstellungen werden häufig als *wicked problems* beschrieben und sind unter anderem durch instabile Rahmenbedingungen, komplexe Wechselwirkungen, hohe Anforderungen an Flexibilität sowie eine starke Abhängigkeit von menschlichen und sozialen Kompetenzen gekennzeichnet [vgl. Rittel und Webber 1973, S.160–167; Hevner et al. 2004, S.81].

Im Anwendungsgebiet der IS umfassen Artefakte nach *Hevner et al. (2004)* **Konstrukte**, **Modelle**, **Methoden** und **Instanzen** [vgl. Hevner et al. 2004, S.77]. Ergänzend erweitern *Peppers et al. (2007)* sowie *Järvinen (2007)* dieses Verständnis um soziale Innovationen sowie neue Eigenschaften technischer, sozialer oder informationsbezogener Ressourcen [vgl. Peppers et al. 2007, S.49; Järvinen 2007, S. 49]. Damit bietet das IS-Forschungsfeld einen geeigneten Rahmen für die Entwicklung, Evaluation und theoretische Fundierung artefaktbasierter Lösungen im Sinne des DSR.

2.3 Leitlinien für die Anwendung von Design Science Research

Die methodisch korrekte Umsetzung eines Forschungsvorhabens nach DSR erfordert die Orientierung an etablierten Leitlinien, die zur Sicherstellung methodischer Strenge sowie zur Erhöhung von Validität und Reliabilität beitragen [vgl. Yin 2009, S.40-41; vgl. Dooley 2002, S.338]. Im Folgenden werden die Leitlinien des DSR anhand der DSR-Prinzipien und des Ordnungsrahmens nach *Hevner et al. (2004)*, der DSR-Methodologie nach *Peppers et al. (2007)* sowie ergänzender Empfehlungen nach *van Aken et al. (2016)* dargestellt. Abschließend wird in **Kapitel 2.3.4** der Forschungsansatz hergeleitet.

2.3.1 Prinzipien und Ordnungsrahmen nach *Hevner et al. (2004)*

Ein grundlegendes Prinzip des DSR besteht darin, dass Erkenntnisse über Designprobleme und deren Lösungen durch das Entwickeln und Anwenden eines Artefakts gewonnen werden [vgl. You und Hands 2019, S.1346-1347]. Zur Unterstützung von Forschenden und Rezipienten formulieren *Hevner et al. (2004)* sieben Prinzipien, die Anforderungen an eine effektive DSR konkretisieren [vgl. Hevner et al. 2004, S.82-83]. Die in der **Tabelle 2** dargestellten Prinzipien sind als Leitplanken zu verstehen und erfordern, insbesondere in interpretativen Feldstudien, kontextsensitives Urteilsvermögen bei der Auswahl und Anwendung [vgl. H. K. Klein und Myers 1999, S.71; Hevner et al. 2004, S.82]. Gleichzeitig sollte jedes Prinzip in geeigneter Form berücksichtigt werden, da die Bewertung der Erfüllung wesentlich durch Gutachter, Herausgeber und Leserschaft erfolgt [vgl. H. K. Klein und Myers 1999, S.71; Hevner et al. 2004, S.82]. Ergänzend zu den sieben Prinzipien empfehlen *van Aken et al. (2016)* eine erweiterte Dokumentation des Designprozesses, einschließlich Eingangsdaten (Problem, Kontext, Analysen, Literatur), verwendeter Designprinzipien, Designentscheidungen bei Adaption und Implementierung sowie Lernkurven und Designalternativen, um die Nachvollziehbarkeit für Wissenschaft und Praxis zu erhöhen [vgl. van Aken et al. 2016, S.7].

Tabelle 2: DSR-Prinzipien

Prinzip	Beschreibung
Design als Artefakt	DSR hat ein praktisch anwendbares Artefakt in Form eines Konstrukts, eines Modells, einer Methode oder einer konkreten Umsetzung zu entwickeln.
Problemrelevanz	DSR hat als Ziel, eine Technologie-basierte Lösung für bedeutsame und relevante Geschäftsprobleme hervorzurufen.
Designevaluierung	Der Nutzen, die Qualität und die Wirksamkeit eines Design-Artefakts müssen durch sorgfältig durchgeführte Evaluationen rigoros nachgewiesen werden.
Forschungsbeitrag	Eine effektive DSR muss klare und überprüfbare Beiträge in den Bereichen des Design-Artefakts, der Design-Grundlagen und/oder der Design-Methodologien liefern.
Forschungsstrenge	DSR stützt sich auf die Anwendung rigoroser Methoden sowohl bei der Erstellung als auch bei der Bewertung des Design-Artefakts.
Design als Suchprozess	Die Suche nach einem effektiven Artefakt erfordert die geschickte Nutzung vorhandener Ressourcen, um gewünschte Ziele zu erreichen und dabei die geltenden Gesetze und Bedingungen der Problemumgebung zu berücksichtigen.
Kommunikation der Forschung	DSR ist sowohl dem technologie- als auch dem management-orientierten Publikum verständlich und ansprechend zu präsentieren.

Neben den Prinzipien beschreiben *Hevner et al. (2004)* einen Ordnungsrahmen, der DSR im Feld der Informationssysteme (IS) verortet und die Koexistenz von **Verhaltensforschung** und **entwurfsorientierter Forschung** als komplementäre Erkenntnislogiken

hervorhebt [vgl. Hevner et al. 2004, S.79-80]. Während Verhaltensforschung auf erklärendes Theoriewissen abzielt, fokussiert entwurfsorientierte Forschung die Entwicklung und Evaluation nützlicher Artefakte. Beide Dimensionen sind jedoch nicht trennbar, weshalb Forschungsrelevanz und -strenge als verbindendes Element zwischen **Anwendungsbereich, entwurfsorientierte Forschung** und **Wissensbasis** zentrale Rollen einnehmen [vgl. ebd., S.79-80]. Der Anwendungsbereich umfasst dabei Menschen, Organisationen und Technologie, deren Zusammenspiel Anforderungen definiert. Die Wissensbasis besteht aus Grundlagen und Methodologien, die sowohl Entwicklungs- als auch Evaluationsaktivitäten wissenschaftlich fundieren und routinemäßige Entwürfe vermeiden helfen [vgl. ebd., S.80][vgl. A. Hevner und Chatterjee 2010, S.18].

Hevner (2007) erweitert diesen Ordnungsrahmen um drei miteinander verknüpfte Zyklen: den **Relevanzzyklus** (Kopplung an den Anwendungskontext, Anforderungen und Akzeptanzkriterien), den **Strengezyklus** (Nutzung und Ausbau der Wissensbasis) und den zentralen **Designzyklus** als iterative Schleife aus Artefaktentwicklung, Evaluation und Rückkopplung [vgl. A. R. Hevner 2007, S.87-91]. Dabei betont *Hevner (2007)*, dass die Konstruktion eines Artefakts ohne gründliche Evaluation nicht ausreicht und die drei Zyklen in einem DSR-Vorhaben klar identifizierbar sein müssen [vgl. ebd., S.88-91]. Zugleich wird die Bedeutung des DSR je nach Zielgruppe unterschiedlich begründet. Akademisch über Beiträge zur Wissensbasis, praktisch über nachweislich nützliche Anwendungen im realen Umfeld [vgl. ebd., S.90]. Ergänzend argumentieren *Hevner und Chatterjee (2010)*, dass Designentscheidungen nicht zwingend auf vollständig ausgearbeiteten Verhaltens- oder mathematischen Theorien basieren müssen, da DSR-Aktivitäten selbst zur Entwicklung und Erforschung solcher Theorien beitragen können [vgl. A. Hevner und Chatterjee 2010, S.18]. Im Sinne dieser Abgrenzung hebt *Iivari (2007)* hervor, dass Design Science im IS-Bereich sich von reiner IT-Praxis durch eine explizit wissenschaftliche, sorgfältig begründete Vorgehensweise unterscheidet [vgl. Iivari 2007, S.88].

2.3.2 DSR-Methodologie nach *Peppers et al. (2007)*

Peppers et al. (2007) konkretisieren DSR durch eine Methodologie, die konzeptionelle Prinzipien, Praxisregeln sowie ein Prozessmodell zur Durchführung und Darstellung von DSR-Vorhaben umfasst [vgl. Peppers et al. 2007, S.49]. Auf Basis der Analyse mehrerer entwurfsorientierter Forschungsarbeiten identifizieren sie sechs zentrale Aktivitäten, die den DSR-Prozess strukturieren [vgl. ebd., S.52–56]. Der Prozess beginnt mit der **Problemidentifikation und -motivation**, in deren Rahmen das Forschungsproblem systematisch erfasst und der wissenschaftliche sowie praktische Mehrwert einer Lösung begründet wird. Darauf aufbauend erfolgt die **Definition der Lösungsziele**, bei der auf Grundlage des Problemverständnisses und vorhandenen Wissens klare Zielsetzungen für das zu entwickelnde Artefakt abgeleitet werden. Die anschließende Phase **Design und Entwicklung** umfasst die Konzeption und Umsetzung des Artefakts unter Festlegung seiner Funktionalität, Architektur und theoretischen Fundierung. In der Phase der **Demonstration** wird das Artefakt zur exemplarischen Lösung konkreter Problem instanzen im Anwendungskontext eingesetzt, um seine grundsätzliche Anwendbarkeit zu veranschaulichen. Die **Evaluation** dient der systematischen Bewertung der Wirksamkeit des Artefakts anhand geeigneter Kri-

terien und Methoden und bildet die Grundlage für mögliche iterative Anpassungen. Den Abschluss des Prozesses bildet die **Kommunikation**, in der das Forschungsproblem, das entwickelte Artefakt sowie die erzielten Ergebnisse sowohl gegenüber der wissenschaftlichen Gemeinschaft als auch gegenüber praxisorientierten Zielgruppen aufbereitet werden.

Die Aktivitäten sind nominell sequenziell angeordnet, jedoch nicht als strikt linear zu verstehen. Vielmehr erlaubt die iterative Natur des DSR unterschiedliche Einstiegspunkte, abhängig vom Ausgangspunkt des Forschungsvorhabens [vgl. Peffers et al. 2007, S.56]. Entsprechend unterscheiden *Peffers et al. (2007)* vier Anwendungstypen (**problemzentriert**, **zielorientiert**, **design- und entwicklungsorientiert** sowie **kontextinitiiert**), die sich primär durch ihre Initiierung und Startaktivität differenzieren. Das Prozessmodell der DSR-Methodologie ist in Abbildung 2 dargestellt.




Abbildung 2: Prozessmodell der DSR-Methodologie

2.3.3 Fortführende DSR-Empfehlungen nach *van Aken et al. (2016)*

Nach *van Aken et al. (2016)* liegen die zentralen Ergebnisse von DSR in innovativen generischen Designs, die in der Praxis erprobt, verstanden und dokumentiert sind und reale Probleme sowie Chancen adressieren [vgl. van Aken et al. 2016, S.1]. Charakteristisch ist zudem die Wechselwirkung zwischen einer **erklärenden** und einer **gestaltenden Komponente**. Während die erklärende Komponente Problemtyp, Ursachen und Zusammenhänge analysiert, entwirft die gestaltende Komponente ein generisches Design in Design-Test-Redesign-Zyklen [vgl. ebd., S.6]. Beide Komponenten sind nicht zwingend zeitlich getrennt. Vielmehr wird ein frühes Skizzieren alternativer Designs nach *van Aken et al. (2016)* empfohlen, um Wissensaufbau und Artefaktentwicklung gegenseitig zu stärken.

Weiter differenzieren *van Aken et al. (2016)* zwischen **Strenge** (wissenschaftlicher Anspruch an die Wirksamkeitsbegründung) und **Designqualität** (Güte von Prozess, Inputs und Designern). Letztere ist keine Garantie für Erfolg, solange das Design nicht im Feld getestet wurde [vgl. ebd., S.6]. Feldtests sind daher zentral, um zunächst Optimierung und anschließend Verallgemeinerung zu ermöglichen; nach Abschluss der Designphase liefern gesättigte Feldtests den Nachweis pragmatischer Validität. Anknüpfend beschreibt *Eisenhardt (1989)* theoretische Sättigung als Zustand, in dem weitere Iterationen nur noch minimalen inkrementellen Erkenntnisgewinn erzeugen [vgl. Eisenhardt 1989, S.545].

2.3.4 Zwischenfazit: DSR als geeigneter Forschungsansatz für diese Arbeit

Die Wahl eines Forschungsansatzes orientiert sich maßgeblich an Forschungsziel, Anwendungsfeld und Ausgangssituation [vgl. Creswell 2006, S.4–6]. Vor diesem Hintergrund erweist sich DSR als geeignet, den Forschungsprozess der vorliegenden Arbeit zu strukturieren.

Das **Forschungsziel** besteht in der theoriegeleiteten Entwicklung eines generalisierbaren Artefakts in Form eines Referenzmodells einer intelligenten Data Pipeline für die Anwendung von Data-Mining-Methoden in der Produktion, primär zur Unterstützung kausal-prädiktiver Instandhaltungsstrategien und als Grundlage für präskriptive Ansätze. DSR zielt auf die Entwicklung innovativer generischer Designs zur Lösung praktischer Problemstellungen und unterstützt damit die systematische Entwicklung, Begründung und Evaluation des Artefakts [vgl. Chandra et al. 2015, S.4039]. Der Transfer zwischen Theorie und Praxis wird dabei durch präskriptives Wissen sowie die Ableitung und Beschreibung generischer Designs über Designprinzipien getragen [vgl. van Aken et al. 2016, S.2]. Designprinzipien sind zugleich praxisorientiert und als Theorien mittlerer Reichweite an konkrete Anwendungskontexte gebunden [vgl. Gregor 2006, S.616].

Das **Anwendungsfeld**, Data-Mining in industriellen Produktionssystemen, ist durch komplexe, dynamische und kontextabhängige Problemstellungen gekennzeichnet, die im Sinne von *Hevner et al. (2004)* den Charakter *wicked problems* aufweisen [vgl. Hevner et al. 2004, S.78]. DSR verbindet erklärende und gestaltende Logiken, indem einerseits theoretische Zusammenhänge analysiert und andererseits Artefakte entwickelt und evaluiert werden [vgl. ebd., S.79–80]. Die enge Rückkopplung an den Anwendungskontext stärkt insbesondere in frühen Phasen die problembezogene Wissensgenerierung [vgl. van Aken et al. 2016, S.6].

Die **Ausgangssituation** ist durch ein praktisches Phänomen geprägt, für das bislang keine integrierte, referenzmodellbasierte Lösung vorliegt. Zudem sind vollständige Anforderungen und Lösungsziele zu Beginn nicht abschließend bestimmbar. Für solche Konstellationen eignet sich ein problemzentrierter Einstieg gemäß dem Prozessmodell von *Peffers et al. (2007)*, da Problemidentifikation und -motivation sowie die schrittweise Ableitung von Zielen und Anforderungen strukturiert unterstützt werden [vgl. Peffers et al. 2007, S.56]. Die Zerlegung komplexer Problemstellungen und die Nutzung vorhandenen Wissens über Problemzustand und erwarteten Nutzen tragen dazu bei, die Komplexität des Vorhabens beherrschbar zu machen [vgl. ebd., S.52–55].

Zusammenfassend liefern *Hevner et al. (2004)* und *Hevner (2007)* einen Ordnungsrahmen zur Balance von Relevanz und Strenge, *Peffers et al. (2007)* ein operationalisierbares Prozessmodell und *van Aken et al. (2016)* ergänzende Empfehlungen zur Dokumentation, Iteration und pragmatischen Validierung. Diese Leitlinien strukturieren den Forschungsprozess, ohne die Methodik vollständig zu determinieren. Die Auswahl und Kombination konkreter Forschungsmethoden erfolgt daher kontextabhängig unter Berücksichtigung von Forschungsziel, Anwendungsfeld und Wissensstand [vgl. Peffers et al. 2007, S.72; H. K. Klein und Myers 1999, S.78]. Vor diesem Hintergrund stellt DSR die geeignete methodische Grundlage für die vorliegende Arbeit dar.

2.4 Forschungsansatz dieser Arbeit

Nach *Creswell (2006)* wird der Forschungsansatz einer wissenschaftlichen Arbeit durch die **Forschungsphilosophie**, das **Forschungsdesign** und die **Forschungsmethoden** bestimmt, deren Auswahl sich an Forschungsfrage, Zielgruppe und persönlichem Erfahrungshintergrund orientiert [vgl. Creswell 2006, S.25–26]. Diese Dimensionen werden im Folgenden auf das vorliegende Forschungsvorhaben bezogen.

Der Arbeit liegt eine **pragmatische Forschungsphilosophie** zugrunde, die dem entwurfstheoretischen Forschungsbereich zuzuordnen ist [vgl. Walls et al. 1992, S.46–47]. Der Pragmatismus unterstützt sowohl empirische Forschung als auch erfahrungsbasiertes Lernen, bei dem Theorie in den Dienst praktischer Problemlösungen gestellt wird [vgl. Ormerod 2006, S.906]. Entsprechend liegt ein Wissensgewinn in der entwurfstheoretischen Forschung dann vor, wenn der Nutzen eines Artefakts klar erkennbar ist, dessen Neuheit gegeben ist und die Wirksamkeit in der praktischen Anwendung nachgewiesen werden kann [vgl. March und Smith 1995, S.260; Hevner et al. 2004, S.77]. Vor diesem Hintergrund verfolgt die Arbeit das Ziel, sowohl einen wissenschaftlichen Beitrag zur Wissensbasis als auch einen praktischen Nutzen im Anwendungskontext zu leisten.

Das **Forschungsdesign** orientiert sich an den Leitlinien des DSR und folgt dem problemzentrierten Ansatz der DSR-Methodologie nach *Peppers et al. (2007)*. In Anlehnung an *Yin (2009)* ist das Forschungsdesign als logischer Plan zu verstehen, der den Weg von der Forschungsfrage zu den Ergebnissen strukturiert [vgl. Yin 2009, S.26]. Die zentralen Aktivitäten des DSR dienen dabei als ordnendes Gerüst für den Forschungsprozess, wobei deren Umsetzung nicht strikt sequentiell erfolgt, sondern iterativ und situationsabhängig ausgestaltet ist. Die eingesetzten **Forschungsmethoden** spezifizieren die einzelnen Forschungsphasen [vgl. Barratt et al. 2011, S.340]. Das resultierende Forschungsdesign ist in **Abbildung 3** dargestellt.




Abbildung 3: Forschungsdesign dieser Arbeit

Die Forschungsphase **Problemidentifikation und -motivation** umfasst die strukturierte Analyse theoretischer Grundlagen, die Identifikation der Forschungslücke sowie des praktischen Handlungsbedarfs im Kontext der Anwendung von Data-Mining-Methoden in der industriellen Instandhaltung. Diese Phase wird durch eine systematische Literaturrecherche nach *vom Brocke et al. (2009)* gestützt. Darauf aufbauend erfolgt die **Definition der Ziele einer Lösung**, in der Zielsetzungen und Anforderungen an das zu entwickeln-

de Artefakt unter Einbezug theoretischer Erkenntnisse und expliziten Domänenwissens abgeleitet werden. In der Phase **Design und Entwicklung** wird ein theoriegeleitetes Referenzmodell einer intelligenten Data Pipeline konzipiert, das primär kausal-prädiktive Instandhaltungsstrategien unterstützt und zugleich als strukturelle Grundlage für präskriptive Ansätze dient. Die Forschungsphase **Demonstration** dient der exemplarischen Anwendung des Referenzmodells in realen industriellen Kontexten, um dessen grundsätzliche Anwendbarkeit und Umsetzbarkeit zu veranschaulichen. Dies erfolgt im Rahmen einer eingebetteten Multifallstudie nach *Yin (2014)*. Die anschließende **Evaluation** zielt auf eine analytische Beurteilung der Zweckmäßigkeit, Anwendbarkeit und Übertragbarkeit des Referenzmodells ab. Hierzu werden qualitative, semistrukturierte Experteninterviews nach *Lamnek (2016)* eingesetzt, die eine kriteriumsgeleitete Bewertung aus unterschiedlichen fachlichen Perspektiven ermöglichen. Die Forschungsphase **Kommunikation** umfasst die strukturierte Darstellung und Diskussion der Ergebnisse innerhalb der wissenschaftlichen Gemeinschaft sowie gegenüber praxisorientierten Zielgruppen.

Über alle Forschungsphasen hinweg wird ein **abduktiv-explorativer Forschungsansatz** verfolgt. Abduktion beschreibt einen rückwärtsgerichteten Denkprozess, bei dem aus beobachteten Phänomenen plausible Erklärungen oder Hypothesen abgeleitet werden, ohne dass alle relevanten Fakten im Vorfeld vollständig bekannt sind [vgl. Samuels 2000, S.214–217]. Die explorative Ausrichtung unterstützt die strukturierte Erschließung bislang unzureichend verstandener Problemfelder sowie die systematische Entwicklung weiterführender Fragestellungen [vgl. Creswell 2006, S.10].

Im Sinne der koexistierenden erklärenden und gestaltenden Komponente werden Analyse-, Design- und Evaluationsaktivitäten iterativ miteinander verknüpft [vgl. van Aken et al. 2016, S.6]. Dieses zyklische Vorgehen ermöglicht eine frühzeitige Reflexion von Erkenntnissen und Designentscheidungen und unterstützt einen konsequent lösungsorientierten Forschungsprozess [vgl. Koppenhagen et al. 2012, S.4–6]. Ergänzend erfolgt ein forschungsbegleitender Austausch mit der wissenschaftlichen Gemeinschaft, unter anderem in Form von Publikationen, Konferenzbeiträgen sowie schutzrechtsbezogenen Veröffentlichungen.

2.5 Methodische Vorgehensweise

Ziel dieser Arbeit ist die Entwicklung eines theoriegeleiteten, abstrahierenden Referenzmodells einer intelligenten Data Pipeline für die Anwendung von Data-Mining-Methoden in der Produktion. Das Referenzmodell unterstützt kausal-prädiktive Instandhaltungsstrategien und ist offen gestaltet, um Übertragbarkeit und Skalierbarkeit auf vergleichbare industrielle Anwendungsszenarien zu ermöglichen. Die Arbeit folgt einem artefaktorientierten, designwissenschaftlichen Forschungsverständnis, bei dem die systematische Entwicklung und Bewertung eines Artefakts im Mittelpunkt steht. Die Modellentwicklung erfolgt primär theorie- und literaturbasiert und wird durch Erkenntnisse aus einer prototypischen Implementierung sowie reflektierte Erfahrungen aus dem industriellen Anwendungskontext ergänzt. Empirische Methoden dienen der exemplarischen Konkretisierung, Demonstration und analytischen Bewertung der praktischen Anwendbarkeit und Übertragbarkeit des Referenzmodells, nicht der statistischen Generalisierung. Zur Umsetzung dieses Vorgehens

werden komplementäre qualitative Forschungsmethoden kombiniert, die entlang der zentralen Aktivitäten des DSR eingesetzt werden und sowohl die strukturierte Ableitung als auch die Demonstration und Evaluation des entwickelten Artefakts unterstützen. Im Folgenden werden in **Kapitel 2.5.1** die systematische Literaturrecherche nach *vom Brocke et al. (2009)*, in **Kapitel 2.5.2** die eingebettete Multifallstudie nach *Yin (2014)* sowie in **Kapitel 2.5.3** die Methoden der semistrukturierten Experteninterviews nach *Lamnek (2016)* dargelegt.

2.5.1 Systematische Literaturrecherche nach *vom Brocke et al. (2009)*

Die vorliegende Arbeit soll den Einsatz von Instandhaltungsstrategien in der Produktion, die auf Datenanalysen und einer bestimmten IT-Infrastruktur beruhen, erforschen. Dazu wurde der Literature Review Ansatz nach *vom Brocke et al. (2009)* angewendet. Dabei wird auf das Wissen aus den theoretischen Grundlagen aus **Kapitel 3** aufgesetzt und dieses mit qualitativen Papern ergänzt. Nach *Baker (2000)* und *Hevner et al. (2004)* betrachtet eine Literaturrecherche die für den Forschungskontext relevanten Quellen und stellt die Relevanz und Rigorosität der Forschung klar. Dabei wird zum einen die Relevanz aufgezeigt, indem die Untersuchung bereits bestehenden Wissens vermieden wird und zum anderen wird dargelegt, dass die Rigorosität durch die Nutzung von vorhandenem Wissen erreicht wird [vgl. Baker 2000, S.219; Hevner et al. 2004, S.88]. In **Abbildung 4** wird der Literature Review Ansatz in Anlehnung an *vom Brocke et al. (2009)* veranschaulicht.



Abbildung 4: Literature Review Ansatz

Die in **Abbildung 4** angegebenen Schritte nach *vom Brocke et al. (2009)* bieten eine systematische Anleitung für das Erstellen von Literaturübersichten und betonen die Wichtigkeit einer umfassenden und transparenten Dokumentation des Literaturrechercheprozesses [vgl. Brocke et al. 2009, S.6-9]. Der erste Schritt **(I)** umfasst die Festlegung des Umfangs und der Art der Literaturübersicht. Hierzu wird die von *Cooper (1988)* entwickelte Taxonomie herangezogen, welche Literaturübersichten entlang zentraler Charakteristika strukturiert. Diese umfasst den Fokus der Übersicht (Ergebnisse, Methoden, Theorien oder Anwendungen), die Zielsetzung (Integration, kritische Analyse sowie Identifikation zentraler Problemstellungen), die Perspektive (neutral oder kritisch), den Abdeckungsgrad der betrachteten Literatur (vollständig, repräsentativ oder selektiv), die Organisationsform (historisch, konzeptionell oder methodologisch) sowie die adressierte Zielgruppe. Die Taxonomie dient als analytischer Rahmen zur transparenten Einordnung und Abgrenzung der im weiteren Verlauf dargestellten Literaturanalyse. Der zweite Schritt **(II)** umfasst die Kon-

zeptualisierung des Forschungsfeldes sowie die Festlegung zentraler Schlüsselbegriffe. Ziel ist es, eine strukturierte Vorstellung sowohl etablierter als auch potenziell relevanter Wissensbereiche zu entwickeln [vgl. Torracco 2005, S.359]. Nach *von Brocke et al. (2009)* sind Schlüsselbegriffe klar zu definieren, Konzeptmapping zur Identifikation relevanter Suchbegriffe zu verwenden und maßgebliche Lehrbücher sowie Enzyklopädien zu konsultieren, um ein fundiertes Verständnis der wichtigsten Konzepte zu erlangen [vgl. Baker 2000, S.222; Zorn und N. Campbell 2006, S.175; Rowley und Slack 2004, S.36]. Der dritte Schritt (III) umfasst die systematische Durchführung der Literaturrecherche. Aufbauend auf der konzeptionellen Rahmung erfolgt die Identifikation relevanter wissenschaftlicher Beiträge anhand eines strukturierten Suchprozesses, der eine fortlaufende Evaluation der Ergebnisse einschließt. Diese Evaluation dient der sukzessiven Eingrenzung der Literatur durch die Analyse von Titeln, Abstrakta sowie, bei inhaltlicher Relevanz, vollständigen Texten. Die Literatursuche basiert auf einer schlagwortgestützten Recherche in einschlägigen wissenschaftlichen Datenbanken. Neben der direkten Suche werden sowohl vorwärtsgerichtete als auch rückwärtsgerichtete Zitieranalysen berücksichtigt, um aktuelle sowie grundlegende Arbeiten systematisch zu erfassen. Zur Sicherstellung einer internationalen und fachlich fundierten Literaturbasis werden wissenschaftliche Suchmaschinen herangezogen, die entweder eigene Datenbestände verwalten oder den Zugriff auf relevante Literaturdatenbanken ermöglichen. In diesem Kontext werden insbesondere *Google Scholar*, *ScienceDirect* und *IEEE Xplore* berücksichtigt. Der vierte Schritt (IV) umfasst die systematische Analyse und Strukturierung der identifizierten Literatur. Ziel ist es, die ausgewählten Forschungsarbeiten geordnet zu vergleichen und inhaltlich zu synthetisieren. Hierzu wird eine Konzeptmatrix verwendet, wie sie von *Salipante et al. (1982)* entwickelt und von *Webster und Watson (2002)* für Literaturübersichten im Bereich der Informationssysteme adaptiert wurde. Die Konzeptmatrix ermöglicht eine strukturierte Gegenüberstellung themenbezogener Konzepte anhand definierter Klassifizierungsmerkmale und unterstützt damit die systematische Ordnung, Analyse und Integration bestehender Forschungsergebnisse. Im letzten Schritt (V) wird die Forschungsagenda entwickelt, die auf der Synthese der Literatur basiert und offene Forschungsfragen sowie wenig erforschte Bereiche identifiziert.

2.5.2 Eingebettete Multifallstudie nach Yin (2014)

Zur Demonstration und analytischen Bewertung des theoriegeleitet entwickelten Referenzmodells wird eine eingebettete Multifallstudie nach *Yin (2014)* eingesetzt. Fallstudien eignen sich insbesondere zur Untersuchung komplexer, kontextabhängiger Phänomene in realen Anwendungsumgebungen und sind damit für artefaktorientierte Forschungsansätze im Sinne des Design Science Research geeignet [vgl. Yin 2014, S.4–5]. Ziel ist keine statistische Generalisierung, sondern die nachvollziehbare Prüfung der Übertragbarkeit des Referenzmodells auf vergleichbare industrielle Anwendungsszenarien im Sinne einer analytischen Generalisierung.

Der methodische Ablauf orientiert sich am sechsstufigen Fallstudienprozess nach Yin (2014) (*Plan, Design, Prepare, Collect, Analyze* und *Share*), der eine strukturierte und nachvollziehbare Durchführung empirischer Untersuchungen gewährleistet. In der

Planungs- und Designphase wird geprüft, ob die Fallstudienmethodik zur Beantwortung der Forschungsfrage geeignet ist, und ein konsistentes Fallstudiendesign inklusive Untersuchungseinheiten, Datenerhebungsmethoden und Analyseverfahren festgelegt [vgl. Yin 2014, S.4–5]. In Anlehnung an *Yin (1993)* wird dabei zwischen dem logischen Fallstudiendesign und der operativen Umsetzung der Fallstudienmethodik unterschieden [vgl. Yin 1993, S.33].

Die Vorbereitung und Durchführung der Datenerhebung folgt den Empfehlungen von *Yin (2014)* zur Nutzung multipler Evidenzquellen. Zum Einsatz kommen insbesondere technische Dokumentationen, Archivunterlagen, direkte Beobachtungen, physische Artefakte sowie system- und prozessbezogene Daten aus dem industriellen Anwendungskontext. Die Kombination mehrerer Datenquellen ermöglicht eine methodische Triangulation und stärkt die Konstruktvalidität der Untersuchung [vgl. Yin 2014, S.102–105]. Ergänzend wird gemäß *Yin (2019)* eine transparente Beweiskette zwischen Forschungsfragen, Datenerhebung, Analyse und Ergebnissen sichergestellt.

Die Analyse der erhobenen Daten erfolgt iterativ durch fallinterne Analysen (*within-case analysis*) sowie fallübergreifende Vergleiche (*cross-case analysis*), um Muster, Gemeinsamkeiten und Abweichungen systematisch zu identifizieren [vgl. Eisenhardt 1989, S.539–540; Yin 2014, S.164–168]. Zur Stärkung der internen Validität werden Verfahren wie *pattern matching* und *explanation building* eingesetzt, bei denen empirische Beobachtungen mit theoretisch erwarteten Mustern verglichen und schrittweise zu konsistenten Erklärungszusammenhängen verdichtet werden [vgl. Yin 2014, S.143–147].

Die externe Validität wird nicht über statistische, sondern über analytische Generalisierung adressiert. Durch das Design als Multifallstudie wird eine Replikationslogik umgesetzt, bei der einzelne Anwendungsfälle zur Bestätigung oder Differenzierung theoretischer Annahmen beitragen [vgl. ebd., S.54–56]. Die Auswahl mehrerer Data-Mining-Anwendungsfälle innerhalb einer gemeinsamen industriellen Domäne ermöglicht es, wiederkehrende Muster sowie kontextspezifische Unterschiede herauszuarbeiten und die Übertragbarkeit der Modellstruktur auf vergleichbare Szenarien zu prüfen. Zur Sicherstellung der Reliabilität werden ein standardisiertes Fallstudiendesign sowie eine strukturierte Dokumentation der Datenerhebung und -analyse eingesetzt. Die systematische Erfassung aller relevanten Daten, Entscheidungen und Auswertungsschritte gewährleistet die Nachvollziehbarkeit und prinzipielle Replizierbarkeit des Forschungsprozesses [vgl. ebd., S.45–49]. Insgesamt erfüllt die eingebettete Multifallstudie damit die Anforderungen an methodische Strenge, Validität und Reliabilität im Kontext eines designwissenschaftlich geprägten Forschungsvorhabens [vgl. Yin 2009, S.40–41; Dooley 2002, S.338].

Yin (2014) unterscheidet innerhalb der Fallstudienmethodik vier Designoptionen, die sich aus der Kombination der Dimensionen **Einzelfall** versus **Multifall** sowie **ganzheitlich** versus **eingebettet** ergeben. Die **ganzheitliche Einzelfallstudie** betrachtet einen einzigen Fall in seiner Gesamtheit und eignet sich insbesondere dann, wenn es sich um einen außergewöhnlichen, kritischen oder einzigartigen Fall handelt. Ihr Vorteil liegt in der Möglichkeit einer tiefgehenden Analyse, während ihre Aussagekraft durch die fehlende Vergleichbarkeit mit anderen Kontexten stark eingeschränkt bleibt. Demgegenüber erlaubt die

eingebettete Einzelfallstudie eine Differenzierung innerhalb eines einzelnen Falls, indem verschiedene Analyseeinheiten, wie Teilprozesse oder Subsysteme, betrachtet werden. Sie kombiniert die intensive Analyse eines einzelnen Settings mit einer internen Strukturierung, bleibt jedoch auf einen spezifischen Kontext beschränkt und ermöglicht keine Replikationslogik über mehrere Fälle hinweg. Die **ganzheitliche Multifallstudie** erweitert die Perspektive, indem mehrere Fälle untersucht werden, allerdings jeweils auf einer Makroebene, ohne die interne Differenzierung innerhalb der Fälle zu berücksichtigen. Auf diese Weise können Muster über verschiedene Kontexte hinweg identifiziert und die externe Validität erhöht werden, jedoch auf Kosten der Detailtiefe innerhalb der einzelnen Fälle. Schließlich stellt die **eingebettete Multifallstudie** eine Kombination der beiden Dimensionen dar, da sie sowohl die Untersuchung mehrerer Fälle ermöglicht als auch innerhalb dieser Fälle unterschiedliche Analyseeinheiten berücksichtigt. Sie vereint damit die Stärken der anderen Designs: eine robuste externe Validität durch die Replikationslogik zwischen den Fällen sowie eine erhöhte interne Validität durch die differenzierte Analyse auf Mikroebene. Gleichzeitig ist dieses Design mit einem höheren methodischen Aufwand verbunden, da sowohl die Fallauswahl als auch die Datenerhebung und -analyse auf mehreren Ebenen erfolgen muss. Die vier Fallstudiendesigntypen in Anlehnung an Yin (2014) sowie das für die Arbeit definierte Fallstudiendesign sind in der **Abbildung 5** grafisch dargestellt.




Abbildung 5: Fallstudiendesigntypen

Für die vorliegende Arbeit erweist sich die Wahl einer **eingebetteten Multifallstudie** als methodisch folgerichtig. Das Ziel, die praktische Nachweisbarkeit und prinzipielle Anwendbarkeit eines theoriegeleitet entwickelten Referenzmodells einer intelligenten Data Pipeline zur Unterstützung kausal-prädiktiver Instandhaltungsstrategien zu untersuchen, erfordert sowohl die Betrachtung des Referenzmodells als übergeordnete Analyseeinheit (Makroebene) als auch die Analyse konkreter Anwendungskontexte (Mikroebene). Durch die Untersuchung mehrerer Data-Mining-Anwendungen innerhalb einer gemeinsamen Domäne wird eine Replikationslogik umgesetzt, die es erlaubt, wiederkehrende Muster sowie

kontextspezifische Unterschiede systematisch herauszuarbeiten. Auf diese Weise wird keine statistische Generalisierbarkeit angestrebt, sondern eine analytische Generalisierung im Sinne der Übertragbarkeit der Modellstruktur auf vergleichbare Anwendungsszenarien unterstützt. Das eingebettete Fallstudiendesign ermöglicht es darüber hinaus, die intelligente Data Pipeline nicht ausschließlich auf der Makroebene des Referenzmodells zu betrachten, sondern auch einzelne Substrukturen und Komponenten der Implementierung differenziert auf der Mikroebene zu analysieren. Damit wird ein Forschungsdesign gewählt, das die methodischen Anforderungen der Arbeit erfüllt und eine nachvollziehbare empirische Nachweisbarkeit der theoretisch hergeleiteten Modellstruktur im industriellen Kontext ermöglicht.

2.5.3 Semistrukturiertes Experteninterview nach *Lamnek (2016)*

Sonnenberg und vom Brocke (2012) unterscheiden Evaluationsmethoden im Kontext der DSR-Forschung in Abhängigkeit von ihrer zeitlichen Verortung im Forschungsprozess. Dabei differenzieren sie zwischen *ex ante* Evaluationen, die vor der Umsetzung oder Konstruktion eines Artefakts erfolgen, und *post ante* Evaluationen, die nach der Konzipierung und Implementierung durchgeführt werden. Im Kontext der vorliegenden Arbeit ist die Evaluation als *post ante* Evaluation einzuordnen, da das entwickelte Referenzmodell einer intelligenten Data Pipeline sowohl konzipiert als auch exemplarisch in einem industriellen Produktionsumfeld implementiert wurde. Als geeignete Evaluationsmethode für diese Phase führen *Sonnenberg und vom Brocke (2012)* unter anderem Experteninterviews an. Diese ermöglichen eine differenzierte und kriteriumsgeleitete Beurteilung eines Artefakts durch Fachpersonen und lassen zugleich Raum für unerwartete Erkenntnisse und ergänzende Perspektiven [vgl. Lamnek und Krell 2016, S.690]. Ziel der *post ante* Evaluation mittels Experteninterviews ist es, den wissenschaftlich fundierten Nachweis zu erbringen, dass das entwickelte Artefakt eine adäquate Lösung für das adressierte Problem darstellt, in der praktischen Anwendung anwendbar und nützlich ist und darüber hinaus Rückschlüsse auf zugrunde liegende Gestaltungsprinzipien zulässt, die theoretisch reflektiert und abstrahiert werden können [vgl. Sonnenberg und vom Brocke 2012, S.76-78].

Zur Evaluation des im DSR entwickelten Referenzmodells werden semistrukturierte Experteninterviews auf Basis der qualitativen Interviewmethodik nach *Lamnek (2016)* durchgeführt. Ziel ist eine kriteriumsgeleitete Beurteilung der Zweckmäßigkeit, Angemessenheit und Praxistauglichkeit des Referenzmodells im industriellen Anwendungskontext. Das semistrukturierte Format ermöglicht dabei eine vergleichbare Bearbeitung zentraler Evaluationskriterien, lässt jedoch zugleich Raum für kontextspezifische Einordnungen und erfahrungsbasierte Ergänzungen der Interviewten. Der Gesamtprozess ist im Ablaufmodell in **Abbildung 6** zusammengefasst.

Die Interviews folgen dem Prinzip der Teilstandardisierung. Nach *Lamnek (2016)* strukturiert der Leitfaden die Themenfelder, während Formulierung, Reihenfolge und Vertiefungen situativ angepasst werden, um Offenheit und Situationsangemessenheit sicherzustellen. Die Interviews werden nach Möglichkeit im gewohnten Arbeitsumfeld der Befragten ge-




Abbildung 6: Ablaufmodell des Experteninterviews

führt, wobei die sprachliche Gestaltung sich am Ausdrucksvermögen der Interviewpartner orientiert, um eine gemeinsame Bedeutungsbasis herzustellen. Die Auswahl der Experten erfolgt theoriebasiert und beschränkt sich auf Personen mit spezialisiertem, nicht allgemein verfügbarem Wissen, das über formale Qualifikation oder langjährige Praxiserfahrung in einem klar abgegrenzten Fachgebiet erworben wurde [vgl. Hitzler 1994, S.13–14]. Zur Sicherstellung einer nachvollziehbaren Auswertung werden alle Interviews vollständig aufgezeichnet.

Der Interviewleitfaden wird in Anlehnung an *Lamnek (2016)* in vier zentrale Teile (A–D) gegliedert. Diese Struktur ermöglicht eine systematische, zugleich flexible Gesprächsführung und stellt sicher, dass sowohl theoriegeleitete Bewertungskriterien als auch kontextspezifische Einschätzungen der Experten berücksichtigt werden. **Teil A** bildet den Einstieg in das Interview und dient der Herstellung einer vertrauensvollen Gesprächsatmosphäre sowie der Kontextualisierung des Untersuchungsgegenstands. Entsprechend werden zunächst die berufliche Rolle und der Erfahrungshintergrund der Interviewten thematisiert, um die späteren Aussagen vor dem Hintergrund individueller Perspektiven einordnen zu können. Anschließend werden Zielsetzung und zentrale Ergebnisse der Arbeit kurz erläutert, um einen gemeinsamen Bezugsrahmen für das Interview zu schaffen. **Teil B** des Interviewleitfadens fokussiert die systematische Bewertung des entwickelten Referenzmodells entlang der definierten Evaluationskriterien. Dieser Abschnitt bildet den Kern des Interviews und dient der theoriegeleiteten Erhebung zentraler Artefaktmerkmale. Die Strukturierung entlang der Evaluationskategorien stellt dabei eine inhaltliche Orientierung dar, während die offene Formulierung der Fragen bewusst Raum für Vertiefungen und differenzierte Einschätzungen lässt. **Teil C** greift spezifische, praxisorientierte Themenfelder auf, die sich aus dem Erkenntnisinteresse der Dissertation ergeben. In diesem Abschnitt wird gezielt Expertenwissen zu Verfahren, Anwendungsszenarien und Herausforderungen im industriellen Kontext erhoben. Die thematische Gliederung erlaubt es, komplexe Sachverhalte differenziert zu erfassen, ohne normativ einzugreifen oder suggestive Fragestellungen zu verwenden. Mit **Teil D** schließt der Interviewleitfaden mit einer offenen Reflexionsphase ab. Ziel dieses Abschnitts ist es, den Interviewten die Möglichkeit zu geben, eigene Schwerpunkte zu setzen, kritische Einschätzungen zu formulieren

oder Aspekte einzubringen, die im strukturierten Verlauf des Interviews nicht explizit adressiert wurden. Dabei kommen insbesondere narrative, reflektierende und bilanzierende Fragetypen zum Einsatz.

Die Auswertung der im Rahmen der Experteninterviews erhobenen qualitativen Daten erfolgt in Form einer evaluativen qualitativen Inhaltsanalyse in Anlehnung an *Kuckartz (2018)*. Ziel dieser Vorgehensweise ist es, die im Interviewmaterial enthaltenen Bewertungen und Einschätzungen systematisch und nachvollziehbar entlang der definierten Evaluationskriterien zu analysieren. Als Grundlage der Analyse werden sämtliche Interviews vollständig aufgezeichnet und anschließend nach einem inhaltlich-semantic Transkriptionsschema wortgetreu verschriftlicht. Die Transkription dient als Arbeitsgrundlage für die strukturierte Auswertung und die eindeutige Referenzierung einzelner Aussagen im Ergebnisteil. Die vollständigen Interviewtranskripte liegen in anonymisierter Form vor und bilden die Grundlage der qualitativen Auswertung. In Übereinstimmung mit etablierten Vorgehensweisen der qualitativen Inhaltsanalyse werden die vollständigen Transkripte nicht im Anhang der Arbeit abgebildet. Stattdessen werden im Rahmen der Ergebnisdarstellung ausgewählte, anonymisierte Interviewaussagen exemplarisch zitiert, um zentrale Bewertungen und Argumentationsmuster transparent zu belegen. Die Transkription orientiert sich an vereinfachten, inhaltsanalytisch geeigneten Regeln nach *Kuckartz (2018)* und verzichtet bewusst auf gesprächsanalytische Feinnotation, da der Fokus der Untersuchung auf der inhaltlichen Evaluation des entwickelten Referenzmodells liegt. Die angewandten Transkriptionsregeln sind in **Tabelle 3** zusammengefasst. Zur Sicherstellung der Nachvollziehbarkeit wurden die Interviews inhaltlich-semantic transkribiert und redaktionell bereinigt. Jeder Sprecherbeitrag wurde als eigener Absatz erfasst und fortlaufend nummeriert. Verweise in der Evaluation erfolgen über Interview-ID und Absatznummer. Die Kategorienlogik der qualitativen Inhaltsanalyse orientiert sich unmittelbar an den zuvor definierten Evaluationskriterien. Diese fungieren als deduktiv abgeleitete Hauptkategorien und bilden den zentralen Bezugsrahmen für die Analyse der Interviewtranskripte. Sämtliche relevanten Textstellen werden regelgeleitet den entsprechenden Evaluationskriterien zugeordnet, sodass eine konsistente und transparente Bewertung des Referenzmodells gewährleistet ist. Ergänzende, kontextspezifische Aspekte werden innerhalb der bestehenden Kategorien berücksichtigt, ohne die zugrunde liegende Kategorienstruktur zu verändern. Die Analyse der Interviewtranskripte erfolgt unter Berücksichtigung der von *Kuckartz (2018)* formulierten Gütekriterien qualitativer Inhaltsanalyse. Dazu zählen insbesondere die Transparenz des methodischen Vorgehens, die Regelgeleitetheit der Auswertung, die Nachvollziehbarkeit der Kategorienzuordnung sowie die konsequente Rückbindung der Interpretation an das empirische Datenmaterial. Auf diese Weise wird eine methodisch fundierte und intersubjektiv nachvollziehbare Evaluation des entwickelten Referenzmodells sichergestellt, die auf den im Rahmen der Experteninterviews erhobenen Einschätzungen basiert.

Im Kontext qualitativer Forschung stellt die theoretische Sättigung ein zentrales Kriterium zur Bestimmung von Umfang und Abschluss der Datenerhebung dar.

Tabelle 3: Vereinfachte Transkriptionsregeln in Anlehnung an Kuckartz

Aspekt	Transkriptionsregel
Transkriptionsform	Inhaltlich-semantische Transkription mit redaktioneller Glättung
Sprecherkennzeichnung	I = Interviewer, E = Experte
Sprache	Übertragung in korrektes Schriftdeutsch unter Beibehaltung der inhaltlichen Aussage
Füllwörter	Irrelevante Füllwörter (z. B. „äh“, „hm“) werden weggelassen
Satzabbrüche	Satzabbrüche werden geglättet, sofern der Sinn eindeutig bleibt
Betonungen	Nicht gesondert gekennzeichnet
Pausen	Nicht explizit transkribiert
Parasprachliche Elemente	Nur bei inhaltlicher Relevanz in eckigen Klammern (z. B. [lacht])
Unverständliche Passagen	Mit [unverständlich] gekennzeichnet
Anonymisierung	Personen, Organisationen und sensible Inhalte werden anonymisiert
Strukturierung	Fortlaufende Absatznummerierung
Referenzierung	Eindeutige Zuordnung jeder Aussage zu Interview-ID und Absatznummerierung

Theoretische Sättigung liegt vor, wenn zusätzliche Datenerhebungen keine substantiell neuen inhaltlichen Erkenntnisse mehr generieren, sondern bestehende Kategorien, Argumentationsmuster oder Deutungslogiken lediglich bestätigen, variieren oder weiter ausdifferenzieren. Sie bezieht sich dabei nicht auf die Vollständigkeit einzelner Aussagen, sondern auf die inhaltliche Stabilität und Kohärenz der entwickelten thematischen Struktur [vgl. Lamnek und Krell 2016, S.182; Glaser und Strauss 2017, S.224–228]. Im Rahmen einer evaluativen qualitativen Inhaltsanalyse bedeutet theoretische Sättigung, dass die zentralen Bewertungskategorien hinreichend empirisch angereichert sind und sich über verschiedene Interviews hinweg konsistent reproduzieren lassen. Entscheidend ist dabei nicht die absolute Anzahl der Interviews, sondern der Erkenntnisfortschritt in Bezug auf das jeweilige Forschungsinteresse. Sobald sich wiederkehrende Argumentationsmuster, stabile Bewertungslogiken und keine grundlegend neuen Perspektiven mehr zeigen, kann von einer ausreichenden empirischen Fundierung der Analyse ausgegangen werden. Vor diesem Hintergrund wird theoretische Sättigung in dieser Arbeit als methodisches Kriterium zur Begründung des Stichprobenumfangs herangezogen. Sie dient zugleich als Qualitätsmerkmal der qualitativen Auswertung, da sie sicherstellt, dass die Analyse auf einer hinreichenden thematischen Tiefe und argumentativen Breite basiert und die interpretativen Schlussfolgerungen nicht auf vereinzelten oder zufälligen Einschätzungen beruhen.

Die Durchführung der Experteninterviews richtet sich an ausgewählte Fachexperten mit vertieftem Domänenwissen in für die Arbeit relevanten Themengebieten. Dazu zählen insbesondere die Bereiche Instandhaltung, Produktion, IT-Architektur sowie Data Science.

Die Auswahl der Interviewpartner erfolgt zielgerichtet nach dem Prinzip des *theoretical sampling*, bei dem nicht repräsentative Zufallsstichproben, sondern theoretisch relevante Fälle berücksichtigt werden, die aufgrund ihrer spezifischen Expertise einen hohen Erkenntnisgewinn für die Evaluation des entwickelten Referenzmodells erwarten lassen. Die Experteninterviews sind als zweistufiges Erhebungsdesign konzipiert, das eine schrittweise und kontextuell erweiterte Evaluation ermöglicht. In einer ersten Erhebungswelle werden Interviews innerhalb eines gemeinsamen Produktionsstandorts in mehreren fahrzeugproduzierenden Gewerken durchgeführt. Diese initiale Phase dient der artefaktnahen Evaluation des Referenzmodells unter vergleichbaren organisatorischen und technischen Rahmenbedingungen und erlaubt eine fokussierte Beurteilung zentraler Aspekte wie Praxistauglichkeit, Verständlichkeit und interne Konsistenz der Modellstruktur. Aufbauend darauf erfolgt in einer zweiten Erhebungswelle eine gezielte Erweiterung der Stichprobe auf weitere nationale und internationale Produktionsstandorte sowie unterschiedliche Konzerngesellschaften und Werkstypen. Durch die bewusste Variation der Anwendungskontexte wird die Evaluation um unterschiedliche organisatorische, technische und geografische Rahmenbedingungen ergänzt. Der Fokus dieser zweiten Phase liegt insbesondere auf der Untersuchung von Skalierbarkeit, Übertragbarkeit und Reproduzierbarkeit der Modellstruktur über den ursprünglichen Anwendungskontext hinaus. Auf diese Weise wird eine kontextuelle Triangulation der Evaluation erreicht, die es erlaubt, robuste Muster sowie kontextspezifische Unterschiede systematisch herauszuarbeiten. Die Dauer der Interviews liegt im Regelfall zwischen 45 und 60 Minuten und variiert in Abhängigkeit von der Gesprächsdynamik sowie der inhaltlichen Tiefe der eingebrachten Einschätzungen. Die Anzahl der durchgeführten Interviews orientiert sich am Erkenntnisfortschritt der Untersuchung und wird iterativ erweitert, um eine hinreichende Abdeckung der Evaluationskriterien über unterschiedliche Anwendungskontexte hinweg sicherzustellen. Zur besseren Nachvollziehbarkeit und Kontextualisierung des zu bewertenden Artefakts werden den Interviewpartnern während der Interviews ausgewählte Präsentationsfolien zur Verfügung gestellt, die zentrale Elemente des Referenzmodells veranschaulichen. Die Datenauswertung erfolgt im Anschluss an die Interviewdurchführung und wird im Detail in **Kapitel 7.2** erläutert. Der Gesamtprozess der Experteninterviews ist im in **Abbildung 6** dargestellten Ablaufmodell zusammengefasst.

3 Theoretische Grundlagen

Für das Verständnis der vorliegenden Arbeit und das Erkennen der Zusammenhänge der Teilgebiete, wird im Folgenden das grundlegende Wissen übermittelt. In **Kapitel 3.1** werden die theoretischen Grundlagen der Instandhaltung aufbereitet. Darauf folgt in **Kapitel 3.2** die Erläuterung der technischen Anlagendokumentation. Die theoretischen Grundlagen der Datenanalyse werden in **Kapitel 3.4** aufgezeigt. Danach werden in dem **Kapitel 3.5** die Grundlagen der Data Pipeline in der Produktion betrachtet. Abschließend werden im Kapitel **Kapitel 3.5** die theoretischen Grundlagen kritisch geprüft und der weitere Handlungsbedarf identifiziert.

3.1 Instandhaltung

Mit dem Einsatz komplexer Maschinen im produzierenden Umfeld steigen die Anforderungen die Prozesssicherheit zu gewährleisten. Dabei nimmt die Instandhaltung eine wichtige Rolle ein. Ziel dieses Unterkapitels ist die Darlegung der Instandhaltungsbegriffe, -strategien und -werkzeuge. In **Kapitel 3.1.1** werden die Begriffe der Instandhaltung näher erläutert. Darauf folgt in **Kapitel 3.1.2** die Darlegung von Instandhaltungszielen und -strategien. Um die Instandhaltung in den Kontext der Arbeit einordnen zu können, wird abschließend in **Kapitel 3.1.3** die Instandhaltung in der Produktion betrachtet.

3.1.1 Begriffe der Instandhaltung

Instandhaltung wird nach *DIN EN 13306:2018-02* als die Kombination technischer, administrativer und Managementmaßnahmen über den gesamten Lebenszyklus eines Objekts definiert, mit dem Ziel, dessen funktionsfähigen Zustand zu erhalten oder wiederherzustellen, sodass die geforderte Funktion erfüllt werden kann [vgl. DIN EN 13306 2017, S.8]. *DIN 31051:2019-09* konkretisiert diesen Begriff durch die Unterscheidung von vier grundlegenden Instandhaltungsmaßnahmen: Wartung, Inspektion, Instandsetzung und Verbesserung [vgl. DIN 31051:2019-06 2019, S.5–7].

Die **Wartung** umfasst Maßnahmen zum Erhalt des Sollzustands, etwa durch Pflege-, Justier- oder Schmierarbeiten, mit dem Ziel, die Abnutzungsgeschwindigkeit zu reduzieren [vgl. Rötzel und Rötzel-Schwunk 2017, S.19–21]. Die **Inspektion** dient der systematischen Erfassung und Beurteilung des Ist-Zustands einer Betrachtungseinheit, um Produktionsstörungen zu vermeiden und Instandsetzungsmaßnahmen planen zu können [vgl. Haase 2017, S.44]. Die **Instandsetzung** zielt auf die Wiederherstellung der Funktionsfähigkeit nach einem Defekt ab und umfasst je nach Fehlerursache Reparaturen, den Austausch von Komponenten oder eine Kombination beider Maßnahmen [vgl. Apel 2018, S.59–61]. Die **Verbesserung** bezeichnet nachträgliche Änderungen zur Steigerung der Funktionssicherheit, ohne die Hauptfunktion der Betrachtungseinheit zu verändern [vgl. DIN 31051:2019-06 2019, S.6 f.].

Ergänzend differenziert *DIN EN 13306:2018-02* Instandhaltung nach Ausführungszeitpunkt und -art in verschiedene Instandhaltungsarten [vgl. DIN EN 13306 2017, S.34–41]. Die präventive Instandhaltung dient der Vermeidung von Abnutzung und der Reduzierung der Ausfallwahrscheinlichkeit. Sie kann vorausbestimmt erfolgen, wenn Maßnahmen oh-

ne vorherige Zustandsbestimmung nach festen Zeit- oder Nutzungsvorgaben durchgeführt werden, oder zustandsorientiert, wenn Maßnahmen auf Basis erfasster Zustandsdaten abgeleitet werden. Eine weiterführende Form stellt die voraussagende Instandhaltung dar, bei der mithilfe von Datenanalysen Prognosen über den zukünftigen Zustand getroffen werden. Die korrektive Instandhaltung wird nach Eintritt eines Defekts durchgeführt und kann entweder sofort oder zeitlich aufgeschoben erfolgen. Weitere Instandhaltungsarten umfassen unter anderem aktive Instandhaltung, geplante und opportunistische Instandhaltung, ferngesteuerte Instandhaltung, Instandhaltung im Betrieb, Instandhaltung vor Ort, Bediener-Instandhaltung, die Klassifikation von Instandhaltungsebenen sowie die teilweise oder vollständige Ausgliederung von Instandhaltungsaufgaben [vgl. DIN EN 13306 2017, S.34–41].

Neben Instandhaltungsarten beschreibt **DIN EN 13306:2018-02** spezifische Instandhaltungstätigkeiten, die operative Ausprägungen der genannten Maßnahmen darstellen [vgl. ebd., S.34–41]. Hierzu zählen unter anderem Inspektion und Zustandsüberwachung zur Erfassung und Bewertung des Anlagenzustands, Nachweis- und Funktionsprüfungen zur Sicherstellung definierter Anforderungen, Routine-Überprüfungen und Revisionen als präventive Maßnahmen, Fehlerdiagnose und Fehlerortung zur Identifikation von Defekten sowie Wiederherstellungsmaßnahmen, einschließlich zeitlich begrenzter Wiederherstellungen und Grundüberholungen. Ergänzend werden außerordentliche Instandhaltungen bei unvorhersehbaren Ereignissen, die Vorbereitung von Instandhaltungsaufgaben sowie die Erstellung und Umsetzung von Instandhaltungsplänen als zentrale Tätigkeiten definiert.

3.1.2 Instandhaltungsziele und -strategien

Instandhaltungsmaßnahmen verfolgen das Ziel, Produktionsanlagen sicher, verfügbar, zuverlässig und wertstabil zu betreiben [vgl. Leidinger 2017, S.15]. Der Sicherheitsaspekt ist dabei eng mit Health-, Safety-, Security- und Environment-Anforderungen verknüpft, die häufig regulatorisch vorgegeben sind. Die Sicherstellung der Verfügbarkeit ermöglicht die planmäßige Aufnahme der Produktion, während Zuverlässigkeit einen möglichst störungsfreien Betrieb adressiert. Der Werterhalt der Anlage zielt auf eine maximale Restlebensdauer und nachhaltige Nutzung ab. Nach *Strunz (2012)* lassen sich Instandhaltungsziele auf Management- und operative Ziele verdichten. Managementziele umfassen dabei insbesondere entscheidungsbezogene, objektbezogene, wirtschaftliche sowie mitarbeiterbezogene Zielsetzungen, während operative Instandhaltungsziele primär Kosten-, Sicherheits- und Produktionsaspekte adressieren [vgl. Strunz 2012, S.19–20].

Die wirtschaftliche Bedeutung der Instandhaltung spiegelt sich insbesondere in der Produktivitätskennzahl der Overall Equipment Effectiveness (OEE) wider [vgl. Focke und Steinbeck 2018, S.8–10]. Die OEE setzt sich aus den Faktoren Verfügbarkeit, Leistung und Qualität zusammen und dient der quantitativen Bewertung der Anlagenproduktivität. Verluste in diesen Faktoren entstehen unter anderem durch ungeplante Stillstände, reduzierte Prozessgeschwindigkeiten sowie Ausschuss oder Nacharbeit [vgl. Schuh, Kampker et al. 2009, S.105–106]. Instandhaltungsziele sind vom Instandhaltungserfolg abzugrenzen. Der wirtschaftliche Erfolg lässt sich allgemein als Differenz zwischen erbrachter Leistung und entstehenden Kosten definieren [vgl. Biedermann 2004, S.9]. Der Instandhaltungserfolg be-

schreibt nach *Schröder (2010)* die Zielerreichung des Instandhaltungsmanagements unter ökonomischen, ökologischen und sozialen Gesichtspunkten [vgl. W. Schröder 2010, S.34].

Die Instandhaltungsstrategie stellt ein zentrales Element des Instandhaltungsmanagements dar und dient der systematischen Erreichung der definierten Ziele [vgl. DIN EN 13306 2017, S.9]. Sie legt fest, an welcher Anlage welche Maßnahmen in welcher Häufigkeit und zu welchem Zeitpunkt durchgeführt werden [vgl. Biedermann 2008, S.19]. Bei der Auswahl geeigneter Strategien sind gesetzliche, technische, sicherheitsrelevante, produktionsbezogene und wirtschaftliche Rahmenbedingungen zu berücksichtigen [vgl. Ryll 2008, S.11]. Grundsätzlich lassen sich Instandhaltungsstrategien in reaktive und präventive Ansätze unterteilen [vgl. DIN EN 13306 2017, S.34–38; Ryll und Freund 2010, S.26–27]. Die reaktive Instandhaltungsstrategie sieht den Betrieb von Anlagen bis zum Eintritt eines Schadens vor, sodass Maßnahmen erst nach dem Ausfall umgesetzt werden [vgl. Schuh, Kampker et al. 2009, S.40]. Diese Strategie nutzt zwar die maximale Lebensdauer von Komponenten aus, führt jedoch zu ungeplanten Stillständen und erschwelter Instandhaltungsplanung. Präventive Strategien zielen hingegen auf die Reduktion von Abnutzung und Ausfallwahrscheinlichkeit ab, indem Maßnahmen vor Eintritt eines Schadens durchgeführt werden [vgl. DIN EN 13306 2017, S.34]. Innerhalb der präventiven Instandhaltung wird zwischen periodisch vorbeugenden, zustandsabhängigen und vorausschauenden Strategien unterschieden [vgl. Ryll und Freund 2010, S.27]. Die periodisch vorbeugende Instandhaltung erfolgt in festen zeit- oder nutzungsabhängigen Intervallen unabhängig vom tatsächlichen Zustand der Anlage [vgl. Ryll 2008, S.13–15; Ryll und Freund 2010, S.28–29]. Sie bietet eine hohe Planbarkeit und Verfügbarkeitsgarantie, geht jedoch mit einem erhöhten Material- und Ersatzteilverbrauch einher. Die zustandsabhängige Instandhaltungsstrategie basiert auf der Erfassung des Anlagenzustands, etwa durch Inspektionen oder Sensorik, und ermöglicht eine hohe Ausnutzung des Abnutzungsvorrats bei gleichzeitig reduzierten ungeplanten Stillständen [vgl. Schuh, Kampker et al. 2009, S.41–42]. Demgegenüber stehen erhöhte Investitionskosten für die kontinuierliche Zustandsüberwachung. Die vorausschauende Instandhaltungsstrategie stellt eine Weiterentwicklung der zustandsabhängigen Instandhaltung dar. Mithilfe historischer Daten und probabilistischer Modelle werden Prognosen über den zukünftigen Verschleißzustand von Komponenten erstellt, um Instandhaltungsmaßnahmen proaktiv vor einem Ausfall zu planen [vgl. Siener und Aurich 2011, S.16; Garg und Deshmukh 2006, S.217–218]. Die Prognosegüte beeinflusst dabei unmittelbar die Qualität der Instandhaltungsplanung und bildet eine wesentliche Grundlage datengetriebener Instandhaltungsansätze.

3.1.3 Instandhaltung in der Produktion

Produzierende Unternehmen betreiben eine Vielzahl technischer Anlagen, deren zuverlässiger Betrieb eine zentrale Voraussetzung für die wirtschaftliche Fertigung darstellt [vgl. Ambhore et al. 2015, S.3420]. Neben funktionalen Anforderungen und der Sicherstellung einer konstanten Produktqualität ist insbesondere die Anlagenzuverlässigkeit von Bedeutung, die sich maßgeblich in einer hohen Verfügbarkeit widerspiegelt. Ungeplante Stillstände führen zu erheblichen wirtschaftlichen Schäden, weshalb Unternehmen geeignete Instandhaltungsstrategien einsetzen, um diesen Risiken entgegenzuwirken. Vor diesem Hin-

tergrund stellt die Instandhaltung einen wesentlichen Hebel zur Sicherstellung der Anlagenverfügbarkeit und Prozessstabilität dar.

Während der industriellen Revolution hat sich das Themengebiet der Instandhaltung, wie in **Abbildung 7** zu sehen ist, mit der Zeit stark verändert [vgl. J. Lee et al. 2020, S.2; Matyas 2019, S.329]. Während frühe Ansätze überwiegend reaktiv ausgelegt waren, etablierte sich mit zunehmender Technisierung zunächst die präventive und später die zustandsorientierte Instandhaltung. Aktuelle Entwicklungen zielen auf datengetriebene, prädiktive und präskriptive Ansätze ab, die eine vorausschauende Planung und optimierte Entscheidungsfindung ermöglichen. Diese Evolution verdeutlicht den steigenden Reifegrad der Instandhaltung und bildet die Grundlage moderner Produktionssysteme.




Abbildung 7: Evolution der Instandhaltung

Aus der präventiven Instandhaltung leitet sich die zustandsorientierte Instandhaltung ab, die unter dem Begriff **Condition Monitoring** bekannt ist. Dabei werden mithilfe von Sensoren kontinuierlich Messgrößen erfasst, die Rückschlüsse auf den Verschleißzustand von Anlagenkomponenten erlauben [vgl. Winkens et al. 2015, S.106; Mohanty 2015, S.1]. Mit der zunehmenden Verfügbarkeit großer Datenmengen und leistungsfähiger Analysemethoden wurde dieser Ansatz zur vorausschauenden Instandhaltung (**Predictive Maintenance**) weiterentwickelt, bei der zukünftige Anlagenzustände prognostiziert werden [vgl. Daily und Peterson 2017, S.268-269]. Den derzeit höchsten Reifegrad stellt die präskriptive Instandhaltung dar, bei der datenbasierte Handlungsempfehlungen generiert und Instandhaltungsmaßnahmen autonom oder teilautonom angestoßen werden [vgl. J. Lee et al. 2020, S.2].

Eine gemeinsame Grundlage aller modernen Instandhaltungsstrategien ist die sensorbasierte Datenerhebung. Messungen an Produktionsanlagen dienen der objektiven, reprodu-

zierbaren und quantitativen Erfassung physikalischer Größen und ermöglichen die Analyse von Zusammenhängen sowie die Überprüfung technischer Hypothesen [vgl. Mühl 2020, S.1; Bernstein 2017, S.1]. Sensoren fungieren dabei als Schnittstelle zwischen der physikalischen Umwelt und der digitalen Signalverarbeitung, indem sie reale Zustände in strukturierte, zeitlich referenzierte Daten überführen [vgl. Bernstein 2024, S.1-2]. Die grundlegende Funktionsweise sensorischer Messsysteme nach *Puente Leon (2015)* beschreibt einen Signalflossplan, in der ein Aufnehmer die Messgröße erfasst, nachgelagerte Umformungs- und Verarbeitungsschritte ein geeignetes SignalfORMAT bereitstellen und in der Signalverarbeitung informationstragende Parameter zur Ableitung des Messergebnisses extrahiert werden. Die Qualität dieser Sensordaten ist von zentraler Bedeutung, da sie unmittelbar die Aussagekraft nachgelagerter Analyse- und Modellierungsverfahren beeinflusst. Entsprechend erfordert die Auswahl geeigneter Sensorik die Berücksichtigung funktionaler, umgebungsbezogener, signaltechnischer sowie wirtschaftlicher Anforderungen [vgl. Hesse und Schnell 2014, S.3; Parthier 2020, S.175-177; Bernstein 2024, S.6-8]. Für die vorliegende Arbeit steht dabei weniger die konkrete sensorische Ausgestaltung im Vordergrund als vielmehr die Verfügbarkeit einer belastbaren Messdatenbasis als Voraussetzung datengetriebener Instandhaltungsansätze [vgl. M. Becker 2019, S.116-117]. Im Folgenden werden die für diese Arbeit relevanten Strategien **Condition Monitoring**, **Predictive Maintenance** und **Knowledge Based Maintenance** näher erläutert.

Condition Monitoring beschreibt die regelmäßige Erfassung des Anlagenzustands im Betrieb. Die Analyse der Messwerte dient sowohl der Detektion von Anomalien als auch der Beobachtung langfristiger Verschleißentwicklungen [vgl. Kolerus und Wassermann 2017, S.6; Matyas 2019, S.336]. Methodisch lässt sich Zustandsüberwachung als Sequenz aus Zustandserfassung, Zustandsvergleich und Diagnose strukturieren [vgl. Czichos 2019, S.25]. Der Zustandsvergleich erfolgt typischerweise über Referenz-, Soll- oder Schwellenwerte, um aus dem Ist-Zustand belastbare Ableitungen für Instandhaltungsmaßnahmen zu gewinnen [vgl. Kolerus und E. Becker 2022, S.312-313; Schuh, Kampker et al. 2009, S.43, 44]. Als zentrale Zielrichtungen werden u. a. Verfügbarkeitssteigerung, Qualitätssicherung sowie die Unterstützung gesetzlicher bzw. sicherheitsbezogener Anforderungen diskutiert [vgl. Matyas 2019, S.128-129]. Gleichzeitig bestehen Herausforderungen insbesondere in der Auswahl geeigneter Messgrößen sowie im Umgang mit großen, hochfrequenten Datenmengen [vgl. Shahzad und Onils 2018, S.101; M. Chi et al. 2016, S.2207-2208].

Predictive Maintenance stellt eine Weiterentwicklung der zustandsorientierten Instandhaltung dar und zielt darauf, zukünftige Anlagenzustände prognostisch zu bestimmen, um Instandhaltungsmaßnahmen proaktiv planen zu können [vgl. J. Lee et al. 2020, S.2]. Durch sensorbasierte Analysen können unnötige Teilewechsel vermieden, Stillstände reduziert und Ursachen systematischer identifiziert werden [vgl. Pech et al. 2021, S.3-4]. Predictive Maintenance basiert dabei auf der Analyse von Sensordaten sowie auf der systematischen Anwendung statistischer und datenanalytischer Verfahren, um Muster und Strukturen in Prozess- und Maschinendaten zu erkennen und daraus Vorhersagen abzuleiten [vgl. S.-j. Wu et al. 2007, S.1; Ippolito et al. 2021, S.7; Munirathinam und Ramadoss 2014, S.896; Çınar et al. 2020, S.1, 2]. Damit können ausfallbedingte Stillstände potenziell vor Eintritt erkannt werden [vgl. Mobley 2002, S.4, 5]. Prozessual lässt sich Predictive

Maintenance entlang von Datenakquise, Datenvorverarbeitung, Schadensdiagnose und Entscheidungsfindung beschreiben [vgl. G. Xu et al. 2019, S.103]. Für eine hohe Prognosegüte sind Datenqualität, geeignete Vorverarbeitung sowie die Integration zustandsbeschreibender Indikatoren und Domänenwissen wesentlich [vgl. Schuh, Kelzenberg et al. 2021, S.151; Latyshev 2018, S.226-227; Ouadah et al. 2022, S.4282]. In der Literatur werden Diagnose und Prognose als zentrale Bausteine datengetriebener Instandhaltung hervorgehoben; beide unterstützen die Ableitung und zeitliche Planung von Maßnahmen [vgl. G. Xu et al. 2019, S.104-107; K. Wang et al. 2016, S.2-6; Jardine et al. 2006, S.1484-1496]. Entsprechend werden Vorteile insbesondere in reduzierten Stillständen, optimierter Ressourcen- und Ersatzteilplanung sowie verbesserter Koordination gesehen, wobei Investitionen in Sensorik und Analysekompetenz als wesentliche Aufwände zu berücksichtigen sind [vgl. Munirathinam und Ramadoss 2014, S.896; Ciocoiu et al. 2017, S.1176, 1177].

Knowledge Based Maintenance (KBM) erweitert datengetriebene Instandhaltungsansätze um den systematischen Aufbau, die Strukturierung und die Nutzung von Wissen über Anlagen, Prozesse und Produkte mit dem Ziel, Entscheidungsprozesse in der Instandhaltung ganzheitlich zu unterstützen [vgl. Potes Ruiz et al. 2014, S.6-7]. Die zugrunde liegende Wissensbasis kann sich aus Maschinen-, Produkt- und Prozessdaten zusammensetzen und mit unterschiedlichen Instandhaltungs- und Managementansätzen verknüpft werden, darunter risiko-, zustands- und zeitbasierte Instandhaltungsstrategien sowie Konzepte wie Total Productive Maintenance, Life Cycle Costing und Lean Maintenance [vgl. Pawellek 2013, S.8-9]. Kritisch wird in der Literatur jedoch angemerkt, dass zahlreiche bestehende KBM-Ansätze primär die Beziehungen zwischen verschiedenen Managementkonzepten darstellen, ohne den zugrunde liegenden logischen Zusammenhang, den Reifegrad des erzeugten Wissens oder systematische Vorgehensmodelle zur Wissensgewinnung, Modellbildung und Visualisierung hinreichend zu spezifizieren [vgl. Ansari Chaharsoughi 2014, S.11-12; Nemeth, Ansari und Sihm 2019, S.645-646]. Ungeachtet dieser Einschränkungen wird KBM als konzeptionelle Voraussetzung präskriptiver Instandhaltungsansätze eingeordnet, da sie die Ableitung fundierter Handlungsempfehlungen ermöglicht und datengetriebene Entscheidungsprozesse im Instandhaltungsmanagement gezielt unterstützt und erweitert [vgl. Matyas et al. 2017, S.461-464; Nemeth, Ansari, Sihm et al. 2018, S.1040].

3.2 Anlagendokumentation

Die Betrachtung technischer Anlagen über ihren gesamten Lebenszyklus erfordert eine konsistente, vollständige und aktuelle Dokumentation sämtlicher anlagenbezogener Informationen. Die Anlagendokumentation bildet damit eine zentrale Grundlage für den sicheren Betrieb, eine effiziente Instandhaltung sowie die rechtliche und organisatorische Nachvollziehbarkeit technischer Maßnahmen.

Die **technische Anlagendokumentation** umfasst sämtliche Informationen, die eine Anlage von der Beschaffung über Betrieb, Wartung und Instandsetzung bis zur Außerbetriebnahme beschreiben, und stellt sowohl für Betreiber als auch für Hersteller eine zentrale Informationsquelle dar [vgl. Storr et al. 2001, S.559-560; Juhl 2015, S.166-167]. Neben ihrer operativen Funktion erfüllt sie eine haftungsrechtliche Aufgabe, da sie den norm- und regelkonformen Umgang mit der Anlage dokumentiert und gesetzlichen Archivierungspflichten

unterliegt [vgl. Bilek et al. 2012, S.652]. In der Literatur wird zwischen interner und externer technischer Dokumentation unterschieden [vgl. Kothes 2011, S.2-3; Bilek et al. 2012, S.652]. Die interne Dokumentation umfasst unternehmensinterne Unterlagen wie Zeichnungen, Stücklisten, Arbeitspläne, Risikobeurteilungen und Prüfberichte, während die externe Dokumentation beispielsweise Betriebsanleitungen, Datenblätter oder Ersatzteilkataloge beinhaltet. Eine strukturierte und vollständige Dokumentation ist Voraussetzung für den sicheren Anlagenbetrieb sowie für die Einhaltung normativer und sicherheitstechnischer Anforderungen [vgl. Storr et al. 2001, S.560]. Ein wesentlicher Bestandteil der technischen Anlagendokumentation sind Informationen zu Wartung, Reparatur und Störungsbehandlung [vgl. Kothes 2011, S.112-116]. Wartungspläne strukturieren nach *Kothes (2001)* regelmäßig durchzuführende Tätigkeiten und dienen als Orientierungshilfe für Anlagenbediener. Ergänzend werden für Reparaturen konkrete Handlungsempfehlungen, Ersatzteilm Informationen und technische Details dokumentiert [vgl. Apel 2018, S.55-59; Kothes 2011, S.115-116]. Auch bekannte Störfälle können standardisiert beschrieben werden, während bei komplexen Abweichungen spezialisierte Fachkräfte erforderlich sind [vgl. Kothes 2011, S.116-117; Apel 2018, S.170-172]. Die zugrunde liegende Struktur technischer Dokumentationen folgt einer generischen Logik, die weitgehend unabhängig vom konkreten Anlagentyp ist und bereits in frühen Lebenszyklusphasen zur Sicherstellung der Vollständigkeit genutzt werden kann [vgl. Storr et al. 2001, S.562]. Die zunehmende Integration technischer Dokumentationen in IT-Systeme unterstützt dabei die unternehmensweite Verfügbarkeit von Informationen und trägt zur Steigerung von Anlagenverfügbarkeit, Störungsmanagement und Anpassungsfähigkeit von Produktionssystemen bei [vgl. Hudetz und Friedewald 2002, S.67; Soder 2014, S.93-94]. Vor diesem Hintergrund werden zunehmend einheitliche, digitale und sprachenunabhängige Dokumentationsansätze gefordert, während papierbasierte Formen an Bedeutung verlieren [vgl. Gausemeier 2013, S.102; Bilek et al. 2012, S.653].

Die **Digitale Lebenslaufakte** stellt eine IT-gestützte Weiterentwicklung der technischen Anlagendokumentation dar und verfolgt das Ziel, alle anlagenbezogenen Informationen über den gesamten Lebenszyklus hinweg konsistent, aktuell und transparent bereitzustellen [vgl. J. Schmidt et al. 2013, S.142-143]. Nach *DIN 77005-1* umfasst sie sämtliche dokumentierten Informationen einer Anlage in chronologischer Form und bildet damit die Gesamtdokumentation über den Lebenszyklus, einschließlich Eigentums- und Verantwortlichkeitsinformationen [vgl. DIN 77005-1:2018-09 2018, S.1 ff.]. Zur Sicherstellung ihrer Nutzbarkeit werden Anforderungen wie Ganzheitlichkeit, Standardisierung, Anlagenbezogenheit, Vollständigkeit, Dauerhaftigkeit, Erweiterbarkeit und Revisionssicherheit formuliert [vgl. J. Schmidt et al. 2013, S.143]. Ergänzend sind Datenschutz- und Sicherheitsaspekte zu berücksichtigen. Im Kontext digitaler Produktionssysteme steht die Digitale Lebenslaufakte in engem Zusammenhang mit Konzepten wie dem Digitalen Informationszwillings und dem Digitalen Zwillings. Während der Digitale Informationszwillings die strukturierte Verknüpfung technischer Dokumente über den Lebenszyklus beschreibt, bildet der Digitale Zwillings eine umfassende digitale Repräsentation einer Anlage auf Basis cyber-physischer Systeme ab und ermöglicht die kontinuierliche Wieder- und Weiterverwendung lebenszyklusbezogener Informationen [vgl. Schlotmann 2018, S.46; Adler und Masik 2020, S.194; Altenfelder et al. 2021, S.385]. Die Digitale Lebenslaufakte ergänzt diese Konzepte um eine

dokumentenorientierte Perspektive, während Ansätze wie die Verwaltungsschale standardisierte und sichere Zugriffsmöglichkeiten auf anlagenbezogene Informationen bereitstellen [vgl. Schaffner 2019, S.115; Altenfelder et al. 2021, S.386].

3.3 Grundlagen der Datenanalyse

Der Umgang mit Daten jeglicher Art sowie die Nutzung dieser zur Wissensanreicherung, setzt einen gewissen Kenntnisstand in spezifischen Themenfeldern voraus. Mit Hinblick auf die Relevanz des Datengebrauchs dieser Arbeit werden im folgenden Inhalte erläutert, die zum Verständnis der Arbeit beitragen. In **Kapitel 3.3.1** werden die Begrifflichkeiten des Data Science sowie des Data Minings, die die Prozesse für die Datenanalyse liefern, näher betrachtet. Darauf folgend werden in **Kapitel 3.3.2** die Grundlagen der Künstlichen Intelligenz im Detail aufgezeigt. Abschließend erfolgt die Darlegung von Methoden und algorithmischen Grundlagen des Machine und Deep Learning in **Kapitel 3.3.3**.

3.3.1 Data Science und Data Mining

Die Begriffe **Data Science** und **Data Mining** stellen zentrale Themenfelder der vorliegenden Arbeit dar, da sie den methodischen Rahmen für die systematische Analyse, Verarbeitung und Nutzung großer Datenmengen bilden. Data Science wird als Wissenschaft der Datenanalyse verstanden, deren Ziel es ist, aus Daten mittels moderner Technologien zu lernen und daraus verwertbares Wissen zu extrahieren [vgl. Donoho 2017, S.756]. Im Mittelpunkt stehen datengetriebene Erkenntnisprozesse, die durch rechnergestützte Verfahren unterstützt werden und eine Verbindung zwischen Daten, Modellen und Entscheidungsprozessen herstellen.

Data Science ist dabei als interdisziplinäres Forschungsfeld zu verstehen, das sich aus der Schnittstelle mehrerer Fachgebiete zusammensetzt. Zu den zentralen Disziplinen zählen die **Informatik**, die **Mathematik** und **Statistik** sowie das **Domänenwissen** des jeweiligen Anwendungsbereichs [vgl. Akerkar und Sajja 2016, S.763]. Während Informatik sowie mathematisch-statistische Methoden die algorithmische und analytische Grundlage liefern, stellt das Domänenwissen den kontextuellen Bezugsrahmen dar, innerhalb dessen Daten interpretiert, relevante Fragestellungen formuliert und Ergebnisse bewertet werden können. Aus der Kombination dieser Disziplinen ergeben sich weitere Teilgebiete wie das Maschinelle Lernen, die Datenanalyse oder softwaretechnische Aspekte datengetriebener Systeme [vgl. Abdel-Karim 2017, S.58–59].

Zur Umsetzung von Data-Science-Vorhaben sind in der Praxis unterschiedliche Rollen etabliert, deren Aufgabenbereiche sich teilweise überschneiden. Der *Data Scientist* übernimmt eine zentrale Rolle bei der Formulierung der Fragestellungen, der Auswahl geeigneter Analyseansätze sowie der Interpretation der Ergebnisse [vgl. Stockinger et al. 2016, S.62–64]. Ergänzt wird diese Rolle durch den *Data Engineer*, dessen Aufgabe insbesondere in der Bereitstellung, Integration und Vorverarbeitung der Daten mit hinreichend hoher Qualität liegt [vgl. Tamir und S. Miller 2015, S.5]. Die explorative Analyse der Daten erfolgt durch den *Data Analyst*, der statistische Methoden und Visualisierungstechniken einsetzt [vgl. Dong und Triche 2020, S.312–314; Cheng et al. 2023, S.1–2]. Für die Entwicklung, das Training und die Validierung von Machine-Learning-Modellen werden darüber

hinaus spezialisierte Kenntnisse im Bereich des Maschinellen Lernens benötigt [vgl. Abdel-Karim 2017, S.58–59]. In realen Anwendungskontexten sind diese Rollen jedoch nicht strikt voneinander getrennt, sondern werden häufig von interdisziplinären Teams gemeinsam ausgefüllt.

Innerhalb des übergeordneten Rahmens der Data Science stellt Data Mining einen zentralen Prozess dar, dessen Ziel die Identifikation bislang unbekannter, potenziell nützlicher und letztlich verständlicher Muster in umfangreichen Datenbeständen ist [vgl. S. Kumar et al. 2018, S.1]. Dabei werden Daten aus unterschiedlichen Perspektiven analysiert, verdichtet und in Form neuer Informationen nutzbar gemacht [vgl. Aashi Singh und Sharma 2017, S.94]. Ein wesentliches Merkmal besteht darin, dass die gewonnenen Ergebnisse sowohl interpretierbar als auch für den jeweiligen Anwendungskontext nutzbar sein müssen [vgl. Hand et al. 2001, S.1–3].

Mit dem zunehmenden Wachstum verfügbarer Datenmengen entstand der Bedarf nach strukturierten Prozessen zur Wissensgewinnung aus Daten. Vor diesem Hintergrund wurde der Prozess der **Knowledge Discovery in Databases (KDD)** entwickelt, der Data Mining als einen Teil eines umfassenderen Erkenntnisprozesses einordnet [vgl. Fayyad et al. 1996, S.82–83]. Der KDD-Prozess ist als iterativ und interaktiv zu verstehen und umfasst mehrere Schritte, beginnend mit dem Verständnis des Anwendungsbereichs und der Zieldefinition, über die Auswahl, Vorverarbeitung und Transformation der Daten, bis hin zur Anwendung geeigneter Data-Mining-Methoden, der Interpretation der Ergebnisse und der Konsolidierung des gewonnenen Wissens [vgl. Usama Fayyad et al. 1996, S.42][S.2-6]Han.2012. Charakteristisch ist, dass zahlreiche Entscheidungen nicht automatisiert getroffen werden, sondern eine aktive Beteiligung des Anwenders erfordern.

Aufbauend auf dem KDD-Prozess wurde mit dem **Cross Industry Standard Process for Data Mining (CRISP-DM)** ein domänen- und technologieunabhängiges Vorgehensmodell entwickelt, das insbesondere die Übertragung von Geschäftsproblemen in datenanalytische Fragestellungen adressiert [vgl. Wirth und Hipp 2000, S.30; Shafique und Qaiser 2014, S.219]. CRISP-DM strukturiert Data-Mining-Projekte in die Phasen Geschäftsverständnis, Datenverständnis, Datenvorbereitung, Modellierung, Evaluierung und Bereitstellung [vgl. Stanula et al. 2018, S.262; Wirth und Hipp 2000, S.33–35; S. Huber et al. 2019, S.404–405]. Die Phasen sind dabei nicht strikt sequenziell, sondern zyklisch angeordnet, sodass iterative Anpassungen und Rückkopplungen möglich sind.

Sowohl der KDD-Prozess als auch CRISP-DM verdeutlichen, dass Data-Science- und Data-Mining-Vorhaben nicht als rein technische Aufgaben zu verstehen sind, sondern in hohem Maße von kontextuellem Wissen, Zielklarheit und iterativer Abstimmung abhängen. Eine zentrale Rolle nimmt hierbei das Domänenwissen ein, das als eine der drei fundamentalen Säulen der Datenanalyse neben Programmierkenntnissen sowie Kenntnissen in Mathematik und Statistik gilt [vgl. Hirsch et al. 2020, S.3258–3261; Vogel-Heuser et al. 2017, S.1358–1360]. Domänenwissen basiert auf dem erlernten und erfahrungsbasierten Wissen von Experten, die Prozesse, Anlagen und Zusammenhänge des jeweiligen Anwendungsfeldes verstehen und interpretieren können. Dieses Wissen kann sowohl verbal als auch schriftlich weitergegeben werden und ist für die Entwicklung robuster Machine- und Deep-Learning-Modelle von zentraler Bedeutung.

Vor diesem Hintergrund wurden wissensgetriebene Vorgehensweisen für Data-Science-Projekte entwickelt, die die explizite Einbindung von Domänenexperten in den Analyseprozess in den Mittelpunkt stellen. Ein solcher Ansatz wird durch einen Ablaufplan wissensgetriebener Projekte beschrieben, der die Zusammenarbeit zwischen Datenanalysten und Domänenexperten strukturiert und in Anlehnung an *Blum et al. (2022)* in **Abbildung 8** dargestellt ist [vgl. Blum et al. 2022, S.368]. Der Prozess beginnt mit einer gemeinsamen Zieldefinition, gefolgt von der Festlegung der zu erhebenden Daten. Dabei wird zwischen einer Brute-Force-Methode, bei der Daten ohne tiefgehendes Vorwissen mit hoher Abtastrate erhoben werden, und einer wissensbasierten Methode unterschieden, bei der vorhandenes Prozesswissen gezielt zur Datenauswahl genutzt wird. Nach der Datenerhebung erfolgt eine gemeinsame Bewertung der Datenqualität, bevor die eigentliche Datenanalyse mit den Schritten Vorverarbeitung, Feature-Extraktion, Feature-Selektion, Modellbildung, Plausibilisierung und Evaluation durchgeführt wird [vgl. Ertel 2021, S.322–323; T. Schneider et al. 2018, S.1–2; Blum et al. 2022, S.369–370]. Der Analyseprozess ist iterativ ausgelegt, sodass bei unzureichenden Ergebnissen entweder die Datengrundlage überprüft oder das Lernproblem neu definiert wird [vgl. Blum et al. 2022, S.370].




Abbildung 8: Ablaufplan für wissensgetriebene Projekte

Ein zentrales Ziel wissensgetriebener Datenanalyse ist das Verständnis kausaler Zusammenhänge zwischen den betrachteten Variablen [vgl. Graf und H. Müller 2021, S.233; Bauer et al. 2018, S.144; Kauermann 2020, S.390]. Das Wissen über Ursache-Wirkungs-Beziehungen ermöglicht sowohl eine fundierte Auswahl relevanter Variablen als auch eine Steigerung der Modellgenauigkeit. Zur Modellierung kausaler Zusammenhänge stehen in der wissenschaftlichen Literatur verschiedene Ansätze zur Verfügung, mit denen Einflussgrößen, Wirkzusammenhänge und Abhängigkeiten innerhalb technischer Systeme struktu-

riert beschrieben werden können. Gemein ist diesen Ansätzen, dass sie sowohl qualitatives Domänenwissen als auch empirische Erkenntnisse aus historischen Daten nutzen, um Ursache-Wirkungs-Beziehungen explizit darzustellen und für die datengetriebene Analyse nutzbar zu machen. **Kausalitätsgraphen** stellen gerichtete Graphen dar, in denen Einflussparameter auf eine Zielvariable abgebildet werden [vgl. Srivastava et al. 2009, S.1]. **Ursache-Wirkungs-Diagramme** strukturieren bekannte Einflussfaktoren entlang der Kategorien **Mensch**, **Maschine**, **Methode**, **Material**, **Mitwelt**, **Messung** (kurz 6-M) [vgl. Schmitt und Pfeifer 2010, S.746–747]. Signalflussgraphen ermöglichen die Modellierung wechselseitiger Einflüsse zwischen Variablen [vgl. Blum et al. 2022, S.372; Lunze 2010, S.52–53]. Merkmalsentstehungsbäume beschreiben die systematische Ableitung neuer Merkmale aus bestehenden Daten und unterstützen die Modellbildung [vgl. Mende 2020, S.93–96; R. Müller et al. 2019, S.175–177].

3.3.2 Grundlagen der Künstlichen Intelligenz

Das Forschungsgebiet der **Künstlichen Intelligenz (KI)** hat den Ursprung in den Ergebnissen des „*Summer Research Project on Artificial Intelligence*“, das 1956 am Dartmouth College in Hanover (New Hampshire, USA) durchgeführt wurde [vgl. Harwardt und Köhler 2023, S.22]. Die von *John McCarthy* getriebene Konferenz definierte das Ziel der KI, Maschinen zu entwickeln, die in der Lage sind, sämtliche Aspekte menschlicher Intelligenz zu simulieren [vgl. McCarthy et al. 2006, S.12]. Dies stellt jedoch eine Herausforderung dar, da die menschliche Intelligenz mit dem multiplen Intelligenzansatz die sprachliche, musikalische, logisch-mathematische, räumliche, körperlich-kinästhetische, intrapersonale, interpersonale sowie naturalistische Intelligenz umfasst [vgl. Gardner et al. 2011, S.488]. Eine weitere Definition, die die Essenz der KI beschreibt ist nach *Rich (1985)* folgende: „*Artificial intelligence (A.I.) is the study of how to make computers do things that people are better at.*“ Demnach werden die Realisierungsgrenzen kontinuierlich aktualisiert und neue Ziele gesetzt [vgl. Rich 1985, S.122]. Nach *Kreutzer (2019)* bezieht sich Künstliche Intelligenz in präziserer Terminologie auf die Fähigkeit einer Maschine, kognitive Aufgaben zu bewältigen, die normalerweise mit dem menschlichem Verstand assoziiert werden. Dies umfasst die Bereiche Wahrnehmung, Argumentation, selbstständiges Lernen und eigenständiges Finden von Problemlösungen. Dabei können drei Arten von Auswertungen – **Description** (Beschreibung des Status quo), **Prediction** (Vorhersage zukünftiger Entwicklungen) und **Prescription** (Empfehlungen für Handlungen) – sowohl kombiniert als auch isoliert eingesetzt werden [vgl. Kreutzer und Sirrenberg 2019, S.3].

Für ein umfassendes Verständnis der Künstlichen Intelligenz wird diese in **starke** und **schwache Intelligenz** unterteilt [vgl. Buxmann und H. Schmidt 2021, S.6-7; Harwardt und Köhler 2023, S.23; Abdel-Karim 2017, S.64]. Die starke KI strebt an, menschliche Denkprozesse vollständig zu reproduzieren, einschließlich Entscheidungsfindung unter Unsicherheit, Kreativität, Empathie und ein eigenes Bewusstsein. Hingegen zielt die schwache KI darauf ab, spezifische Anwendungsfälle zu lösen, wie beispielsweise Spracherkennung, Navigationssysteme oder Korrekturvorschläge bei Suchvorgängen. Alle aktuellen Entwicklungen im Bereich der Künstliche Intelligenz lassen sich in diese Kategorisierung einordnen. Unabhängig von der Unterteilung stellt das Lernen eine Anforderung für die KI dar. In

diesem Zusammenhang werden die integralen Bestandteile **Machine Learning (ML)** und **Deep Learning (DL)** aufgeführt. *Mitchell (1997)* definiert ML wie folgt: „A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P, if its performance at tasks in T, as measured by P, improves with experience E.“ Demnach fokussiert sich ML auf die Entwicklung technischer Konzepte, die es ermöglichen, neues Wissen aus vorhandenen Erfahrungen zu generieren [vgl. Thomas M. Mitchell 1997, S.2-3]. Dies geschieht durch das Training von ML-Modellen anhand von Datensätzen. Das primäre Ziel dieses Trainings besteht nach *Hartmann (2018)* darin, Muster oder inhärente Gesetzmäßigkeiten in den Daten zu identifizieren. Nach erfolgreichem Training kann das ML-Modell für die Analyse von bisher unbekannten Daten eingesetzt werden. Auf Grundlage der erkannten Muster oder Gesetzmäßigkeiten zieht das System die erforderlichen Schlussfolgerungen, um auf die unbekannten Daten zu reagieren und diese zu interpretieren [vgl. Hartmann 2018, S.232]. Jedoch ist das Lernen von dem Umfang der Daten abhängig, wobei mit steigender Datenmenge die Möglichkeiten des Lernens ebenso steigen [vgl. Harwardt 2022, S.60].

Darüber hinaus stellt die Qualität der verwendeten Daten einen zentralen Erfolgsfaktor für datengetriebene Analyse- und Modellierungsverfahren dar [vgl. Hazen et al. 2014, S.72-73]. Unvollständige, verrauschte oder inkonsistente Daten wirken sich unmittelbar auf die Aussagekraft analytischer Ergebnisse aus und können die Leistungsfähigkeit von Machine- und Deep-Learning-Verfahren erheblich beeinträchtigen [vgl. Pyle 2005, S.23-24]. Um eine hinreichend hohe Datenqualität sicherzustellen, wird in der Literatur ein systematischer Vorverarbeitungsprozess empfohlen, der häufig entlang des **ETL-Paradigmas** (**E**xtract, **T**ransform, **L**oad)strukturiert wird [vgl. Souibgui et al. 2019, S.676-677]. Nach *Souibgui et al. (2019)* ist das Ziel der Datenvorverarbeitung, aus heterogenen Rohdaten einen konsistenten, korrekten und für analytische Verfahren nutzbaren Datensatz zu erzeugen, der als Grundlage für die Anwendung von Machine- oder Deep-Learning-Methoden dient. Die **Extraktionsphase** umfasst dabei die Bereitstellung von Daten aus unterschiedlichen Quellen [vgl. Bansal 2014, S.523]. Im Kontext datengetriebener Analysen ist die explizite Berücksichtigung von Datentypen eine grundlegende Voraussetzung für eine methodisch konsistente Vorverarbeitung und Modellierung. Datentypen klassifizieren Variablen hinsichtlich der Art zulässiger Werte und Operationen und beeinflussen damit, welche Transformations-, Prüf- und Analyseverfahren sinnvoll anwendbar sind [vgl. Abdel-Karim 2017, S.17-23; A. Kohl 2011, S.63-67]. Neben elementaren numerischen, logischen und textuellen Datentypen sind insbesondere zusammengesetzte Datenstrukturen sowie zeitbezogene Informationen relevant. Arrays dienen der Abbildung sequenzieller oder mehrdimensionaler Messwertfolgen, während Zeitstempel, häufig in Form der Unix-Zeit, eine eindeutige zeitliche Referenzierung und damit die Zusammenführung heterogener Datenquellen ermöglichen [vgl. Harris et al. 2020, S.357-358; Zuckarelli 2021, S.95]. Ergänzend ist zwischen strukturierten und unstrukturierten Daten zu unterscheiden [vgl. Reuter et al. 2023, S.51-55]. Strukturierte Daten sind formal eindeutig organisiert und typischerweise direkt in Datenbanksystemen verarbeitbar, wohingegen unstrukturierte Daten, wie beispielsweise Text- oder Bilddaten, vor der Analyse in geeignete Repräsentationen überführt werden müssen [vgl. Fuchslueger 2016, S.69; Brandau 2018, S.3-4]. Für die vorliegende Arbeit bedeutet

dies, dass sensorbasierte Anlagendaten überwiegend als strukturierte, numerische (zeitreferenzierte) Daten vorliegen, während Domänenwissen häufig textuell und damit unstrukturiert erfasst wird; daraus ergeben sich Anforderungen an Vorverarbeitung, Integration und nachgelagerte Modellierungsverfahren. Die **Transformationsphase** zielt darauf, Daten hinsichtlich Struktur, Format und Qualität für nachgelagerte Analyseprozesse aufzubereiten [vgl. Bansal 2014, S.523]. Zu den zentralen Aufgaben der Transformationsphase zählen die Datenbereinigung, Datentransformation, Datenreduktion und Datenintegration [vgl. Pan et al. 2018, S.275-276; A. Fatima et al. 2017, S.51; Sreemathy, Joseph V et al. 2020, S.1447; Sreemathy, Naveen Durai et al. 2021, S.1658]. Die Datenbereinigung dient der Identifikation und Korrektur von Fehlern im Datensatz, wobei zwischen zufälligen und systematischen Fehlern unterschieden wird [vgl. Rahm und Do 2000, S.3; T. Schulz 2022, S.22]. Häufige Fehlerarten sind Rauschen, Ausreißer und fehlende Werte. Rauschen kann beispielsweise durch Filterverfahren reduziert werden, während Ausreißer mithilfe statistischer Methoden wie der 3-Sigma-Regel identifiziert werden können [vgl. Runkler 2015, S.24; Ghosh et al. 2011, S.343; Gorawski et al. 2023, S.219]. Fehlende Werte werden je nach Kontext entfernt oder durch geeignete Schätzverfahren ersetzt, um Informationsverluste zu vermeiden [vgl. T. Schulz 2022, S.22]. Die Datentransformation verfolgt das Ziel, Daten in eine für analytische Verfahren geeignete Repräsentation zu überführen [vgl. Wijaya und Pudjoatmodjo 2015, S.2; El-Sappagh et al. 2011, S.93]. Insbesondere bei unstrukturierten Daten sind Transformationsschritte erforderlich, da diese nicht unmittelbar maschinell verarbeitet werden können [vgl. E. Mehmood und Anees 2022, S.3421-3422]. Zu den etablierten Methoden zählen Normierung, Standardisierung, Diskretisierung sowie die Bildung abgeleiteter Attribute [vgl. T. Schulz 2022, S.22-23; Kohn 2005, S.36; Rasch et al. 2010, S.24-25; García, Ramírez-Gallego et al. 2016, S.7-8]. Da nicht alle Attribute gleichermaßen zur Erklärung des betrachteten Phänomens beitragen, wird ergänzend eine Datenreduktion durchgeführt, um den sogenannten Fluch der Dimensionalität zu vermeiden [vgl. Schendera 2015, S.19; Diouf et al. 2018, S.1; Alexandropoulos et al. 2019, S.22; Y. Zhai et al. 2014, S.16]. Ein zentrales Verfahren stellt hierbei die Merkmalsauswahl dar, bei der irrelevante oder redundante Attribute identifiziert und entfernt werden [vgl. Hall 2000, S.28]. Die Datenintegration schließlich dient der Zusammenführung von Daten aus unterschiedlichen Quellen in einer gemeinsamen Struktur, wobei häufig der Zeitstempel als Referenzvariable genutzt wird, um eine konsistente Zusammenführung heterogener Datensätze zu ermöglichen [vgl. Biswas et al. 2020, S.53-55; T. Schulz 2022, S.23; Tu et al. 2020, S.2300-2301; R. Kim et al. 2016, S.121-122]. Ist die Phase der Datentransformation abgeschlossen, folgt das **Laden** der Daten in eine geeignete Datenbank [vgl. Mukherjee und Kar 2017, S.943]. Dabei können sich Datenanalysten für die Entwicklung von Machine und Deep Learning Modellen in dieser Datenbank bedienen [vgl. Wagh et al. 2021, S.91-94].

3.3.3 Algorithmische Grundlagen des Machine und Deep Learning

Machine- und Deep-Learning-Verfahren stellen zentrale methodische Ansätze für die automatisierte Analyse komplexer Daten dar. Ziel dieses Kapitels ist es, die grundlegenden Methoden und algorithmischen Konzepte des Machine und Deep Learning auf einer abstrahierten Ebene darzustellen und systematisch einzuordnen. Hierzu werden zunächst

die grundlegenden Lernparadigmen erläutert, anschließend zentrale Leistungsmetriken zur Modellbewertung vorgestellt sowie ausgewählte Klassen von Machine- und Deep-Learning-Verfahren eingeordnet. Abschließend werden Modell- und Hyperparameter als wesentliche Einflussgrößen des Lernverhaltens betrachtet. Die dargestellten Grundlagen bilden die konzeptionelle Basis für die nachfolgenden Kapitel.

Grundsätzlich lässt sich Machine Learning in drei zentrale Lernparadigmen unterteilen: Supervised Learning, Unsupervised Learning und Reinforcement Learning [vgl. K. Murphy 2014, S.2; Marsland 2011, S.6–7]. Diese Paradigmen unterscheiden sich insbesondere hinsichtlich der Verfügbarkeit von Zielinformationen sowie der Art und Weise, wie Lernprozesse gesteuert und bewertet werden.

Beim **Supervised Learning** werden Algorithmen auf der Grundlage annotierter Trainingsdaten trainiert, um komplexe Zusammenhänge zwischen Eingabe- und Zielvariablen zu modellieren [vgl. Harwardt und Köhler 2023, S.24]. Der Lernprozess basiert dabei auf einem Trainingsdatensatz, aus dem das Modell die zugrunde liegenden Strukturen und Abhängigkeiten ableitet. Die Bewertung der Güte des trainierten Algorithmus erfolgt typischerweise anhand eines separaten Testdatensatzes, der nicht zur Modellanpassung herangezogen wurde [vgl. Buxmann und H. Schmidt 2021, S.11]. Supervised-Learning-Verfahren finden insbesondere Anwendung bei Klassifikations- und Regressionsproblemen, bei denen valide Zielgrößen vorliegen.

Im Gegensatz dazu stehen beim **Unsupervised Learning** keine annotierten Zielvariablen zur Verfügung. Die Lernalgorithmen sind hier darauf ausgelegt, eigenständig Muster, Strukturen oder Gruppierungen innerhalb der Daten zu identifizieren [vgl. Kreutzer und Sirrenberg 2019, S.3; Alpaydm 2010, S.11]. Typische Anwendungsfälle umfassen unter anderem Clustering-Verfahren, Anomalieerkennung sowie Methoden zur Dimensionsreduktion. Unsupervised Learning ist insbesondere in Szenarien relevant, in denen die Generierung gelabelter Datensätze mit hohem Aufwand verbunden oder nicht möglich ist.

Ein drittes grundlegendes Paradigma stellt das **Reinforcement Learning** dar. Dieser Ansatz verfolgt das Ziel, durch einen iterativen Trial-and-Error-Prozess eine optimale Strategie zur Lösung eines gegebenen Problems zu erlernen [vgl. Gentsch 2018, S.38]. Die Lernstrategie wird dabei kontinuierlich angepasst, indem eine definierte Anreiz- oder Belohnungsfunktion maximiert wird [vgl. Dörn 2018, S.262]. Reinforcement Learning findet vor allem in dynamischen Entscheidungs- und Steuerungsproblemen Anwendung, bei denen sequenzielle Aktionen und deren langfristige Auswirkungen berücksichtigt werden müssen.

Eine weiterführende Ausprägung des Machine Learning bildet das Deep Learning. Es basiert auf **künstlichen neuronalen Netzen (KNN)**, die entwickelt wurden, um die Struktur und Vernetzung biologischer Neuronen im menschlichen Gehirn abstrahiert nachzubilden [vgl. Harwardt 2022, S.60; Buxmann und H. Schmidt 2021, S.14]. Künstliche neuronale Netze bestehen aus mehreren miteinander verbundenen Neuronen, auch als Units bezeichnet, die in unterschiedliche Schichten organisiert sind. Dabei wird zwischen Input-Units, welche die Eingangsdaten aufnehmen, Hidden-Units, die in einer oder mehreren verdeckten Schichten angeordnet sein können, sowie Output-Units, welche die Modellvorhersagen repräsentieren, unterschieden [vgl. Goodfellow et al. 2016, S.6; Rey und Wender

2018, S.16–17; Buxmann und H. Schmidt 2021, S.14–15].

Die Bewertung der Leistungsfähigkeit von Machine- und Deep-Learning-Modellen erfolgt anhand spezifischer Leistungsmetriken, deren Auswahl maßgeblich von der jeweiligen Aufgabenstellung abhängt. Für Klassifikationsprobleme werden häufig Metriken wie Accuracy, Precision, Recall oder der F1-Score herangezogen, während bei Regressionsproblemen insbesondere Fehlermaße wie der Mean Squared Error (MSE) oder der Mean Absolute Error (MAE) Verwendung finden [vgl. Sokolova und Lapalme 2009, S.429–431; Hodson et al. 2021, S.1–2; Dumre et al. 2024, S.1858–1860; Hao und S. Li 2020, S.330–331]. Die Wahl geeigneter Metriken beeinflusst dabei nicht nur den Modellvergleich, sondern auch die Interpretation der erzielten Ergebnisse, insbesondere bei unausgeglichene Datensätzen oder unterschiedlichen Fehlkosten. Die in **Tabelle 17** im **Anhang A** dargestellte Übersicht fasst zentrale Leistungsmetriken zusammen und ergänzt diese um kurze Beschreibungen sowie die zugrunde liegenden mathematischen Definitionen. Dadurch wird eine einheitliche Bewertungsgrundlage geschaffen, die sowohl den Vergleich unterschiedlicher Modelle als auch die Nachvollziehbarkeit der Evaluation unterstützt [vgl. Chicco et al. 2021, S.4–6; Armah et al. 2014, S.418; van Beers et al. 2019, S.441; Zhukov et al. 2017, S.2; L. Fang et al. 2024, S.3; Carrington et al. 2020, S.2–5; Lapin et al. 2018, S.1538].

Aufbauend auf diesen Grundlagen lassen sich verbreitete Machine- und Deep-Learning-Verfahren unterschiedlichen methodischen Klassen zuordnen. Diese Einordnung unterstützt das grundsätzliche Verständnis der Einsatzmöglichkeiten sowie der charakteristischen Eigenschaften der jeweiligen Ansätze. **Decision Trees** modellieren Entscheidungsprozesse in Form einer baumartigen Struktur, in der Daten anhand sukzessiver Merkmalsaufspaltungen in immer homogenere Teilmengen unterteilt werden [vgl. Charbuty und Abdulazeez 2021, S.20-21]. Die Modellvorhersage ergibt sich aus dem Pfad von der Wurzel bis zu einem Blattknoten und ist dadurch gut nachvollziehbar und interpretierbar. **Random Forests** stellen Ensemble-Modelle dar, die aus einer Vielzahl einzelner Entscheidungsbäume bestehen, deren Vorhersagen aggregiert werden [vgl. Biau und Scornet 2016, S.200-203]. Durch die Kombination zufälliger Stichproben der Trainingsdaten sowie zufälliger Merkmalsauswahlen wird die Varianz einzelner Modelle reduziert und die Generalisierungsfähigkeit erhöht. **Logistische Regression** ist ein lineares Klassifikationsverfahren, das die Wahrscheinlichkeit der Zugehörigkeit zu einer Klasse mittels einer logistischen Funktion modelliert [vgl. Sperandei 2014, S.14-18]. Das Modell eignet sich insbesondere für binäre Klassifikationsprobleme und zeichnet sich durch eine hohe Interpretierbarkeit der Modellparameter aus. **Lineare Diskriminanzanalyse** basiert auf der Annahme normalverteilter Klassen und zielt darauf ab, eine lineare Projektion zu bestimmen, die die Klassen maximal voneinander trennt [vgl. Xanthopoulos et al. 2013, S.27-30]. Sie wird häufig eingesetzt, wenn Klassen gut separierbar sind und statistische Annahmen erfüllt werden. **Naive-Bayes-Modelle** beruhen auf dem Bayes-Theorem und der vereinfachenden Annahme bedingter Unabhängigkeit der Eingangsmerkmale [vgl. Shenglei Chen et al. 2020, S.3-4]. Trotz dieser Annahme zeigen sie in vielen Anwendungsfällen eine robuste Leistungsfähigkeit, insbesondere bei hochdimensionalen Datensätzen. **k-Nearest Neighbors** ist ein instanzbasiertes Verfahren, bei dem die Klassifikation oder Regression eines Datenpunkts auf Basis der Ähnlichkeit zu

den nächsten Nachbarn im Merkmalsraum erfolgt [vgl. Z. Zhang 2016, S.2-4]. Das Modell verzichtet auf eine explizite Trainingsphase, ist jedoch sensitiv gegenüber der Wahl der Distanzfunktion und der Nachbarschaftsgröße. **Support Vector Machines** bestimmen eine Trennhyperebene, die den maximalen Abstand zwischen Klassen im Merkmalsraum maximiert [vgl. Mammone et al. 2009, S.283-284]. Durch den Einsatz von Kernel-Funktionen lassen sich auch nichtlinear separierbare Datenstrukturen abbilden. **Multilayer Perceptrons** sind feedforward-neuronale Netze, die aus mehreren Schichten künstlicher Neuronen bestehen [vgl. Murtagh 1991, S.186-189]. Durch nichtlineare Aktivierungsfunktionen können sie komplexe Zusammenhänge zwischen Eingabe- und Zielvariablen modellieren. **Long Short-Term Memory**-Netze sind eine spezielle Form rekurrenter neuronaler Netze, die zur Verarbeitung sequenzieller Daten entwickelt wurden [vgl. van Houdt et al. 2020, S.5931-5933]. Durch interne Speichermechanismen sind sie in der Lage, langfristige zeitliche Abhängigkeiten zu erfassen. **Eindimensionale Convolutional Neural Networks (1D-CNN)** nutzen Faltungsoperationen zur automatischen Extraktion lokaler Muster in eindimensionalen Daten, etwa Zeitreihen [vgl. Arsalan et al. 2024, S.1-3]. Sie sind insbesondere für die Erkennung lokaler Strukturen und wiederkehrender Muster geeignet. **Maximum Mean Discrepancy** ist ein distanzbasiertes Maß zur Quantifizierung von Unterschieden zwischen Wahrscheinlichkeitsverteilungen [vgl. Dziugaite et al. 2015, S.2-5]. Es wird häufig zur Analyse von Datenverschiebungen, zur Modellvalidierung oder im Kontext von Domänenanpassung eingesetzt. **k-Means** ist ein unüberwachtes Clustering-Verfahren, das Datenpunkte auf Basis einer Distanzmetrik in k Gruppen mit minimaler intra-cluster Varianz partitioniert [vgl. Likas et al. 2003, S.452-454]. Es wird häufig zur explorativen Datenanalyse und zur Strukturierung ungelabelter Daten eingesetzt, ist jedoch sensitiv gegenüber der Wahl der Clusteranzahl, der Initialisierung sowie gegenüber Ausreißern.

Im Kontext des Gesamtkonzepts des Referenzmodells werden für überwachte Lernverfahren annotierte Daten vorausgesetzt, die im Rahmen der vorgelagerten Datenaufbereitung bereitgestellt werden. Diese dienen der Modellanpassung anhand von Trainingsdatensätzen sowie der Bewertung der Modellgüte mittels separater Testdatensätze (vgl. **Kapitel 3.3.2**). Die konkrete methodische Ausgestaltung der eingesetzten Supervised-Learning-Verfahren wird in den Fallstudien im Detail aufgegriffen. Ergänzend bietet Tabelle 18 im **Anhang A** einen strukturierten Überblick über ausgewählte Methoden des Supervised Learning im Kontext von Machine Learning und Deep Learning. Die Übersicht dient der vergleichenden Einordnung unterschiedlicher Modellfamilien und stellt deren typische Anwendungsgebiete, charakteristische Stärken und Einschränkungen sowie gängige Evaluationsmetriken zusammen. Die Auswahl der dargestellten Verfahren orientiert sich an ihrer wissenschaftlichen Relevanz und praktischen Verbreitung in aktuellen Forschungs- und Anwendungskontexten und verdeutlicht die Bandbreite algorithmischer Ansätze von klassischen statistischen Modellen bis hin zu tiefen neuronalen Architekturen.

Machine- und Deep-Learning-Modelle werden wesentlich durch ihre Modellparameter und Hyperparameter charakterisiert, die gemeinsam das Lernverhalten sowie die resultierende Modellgüte bestimmen [vgl. Goodfellow et al. 2016, S.98]. Modellparameter

werden während des Trainingsprozesses aus den Daten gelernt und repräsentieren die interne Struktur des Modells, beispielsweise Gewichtungen in neuronalen Netzen oder Trennkriterien in Entscheidungsbäumen [vgl. Luo 2016, S.2-3]. Sie spiegeln damit die im Trainingsdatensatz enthaltenen Muster und Zusammenhänge wider [vgl. Bhamare und Suryawanshi 2018, S.363-365]. Eine beispielhafte Zuordnung von Modellparametern und Hyperparametern für ausgewählte Verfahren ist in **Tabelle 19** im **Anhang A** dargestellt. Die Übersicht verdeutlicht, dass sich Umfang und Bedeutung der jeweiligen Parameterklassen je nach Modelltyp erheblich unterscheiden und sowohl einfache statistische Verfahren als auch komplexe neuronale Architekturen betreffen [vgl. Luo 2016, S.3–4]. Die konzeptionelle Unterscheidung von Modell- und Hyperparametern bildet eine wesentliche Grundlage für das Verständnis von Modellanpassung und Optimierungsstrategien, die in den nachfolgenden Kapiteln im Rahmen konkreter Anwendungs- und Evaluationsszenarien aufgegriffen werden.

3.4 Grundlagen der Data Pipeline in der Produktion

Die Nutzung datenbasierter Verfahren hat im Zuge der Digitalisierung eine zentrale Bedeutung für moderne Produktionssysteme erlangt. Insbesondere im Kontext datengetriebener Instandhaltungsstrategien stellen Daten die wesentliche Ressource für analytische Verfahren dar, während die Data Pipeline die technische und organisatorische Infrastruktur für den kontinuierlichen Datenfluss bereitstellt. Sie verbindet Datenerhebung, -verarbeitung, -speicherung und -analyse zu einem integrierten Gesamtsystem und bildet damit die Grundlage für wissensbasierte Entscheidungsprozesse in der Produktion. Im Folgenden wird in **Kapitel 3.4.1** das Thema Big Data und Smart Data in der Produktion erläutert. Abschließend erfolgt in **Kapitel 3.4.2** die Darlegung unterschiedlicher Data Pipeline Ansätze.

3.4.1 Big Data und Smart Data in der Produktion

Big Data hat sich als grundlegendes Konzept zur Entwicklung innovativer Technologien etabliert, insbesondere in datenintensiven Domänen wie der industriellen Produktion [vgl. W. Lee et al. 2021, S.15]. In Produktionsumgebungen entstehen Daten aus einer Vielzahl heterogener Quellen, darunter Sensordaten aus Anlagenkomponenten sowie Bild- oder Qualitätsdaten aus Prüfsystemen [vgl. Papp et al. 2022, S.80]. Der Begriff Big Data wird dabei häufig entlang der fünf Dimensionen *Volume*, *Variety*, *Velocity*, *Veracity* und *Value* beschrieben, welche Datenmenge, Datenvielfalt, Verarbeitungsgeschwindigkeit, Datenqualität und Anwendungsnutzen adressieren [vgl. Luengo et al. 2020, S.1; Papp et al. 2022, S.80; Tardio et al. 2020, S.210597].

Während *Volume*, *Variety* und *Velocity* primär infrastrukturelle Anforderungen betreffen, sind *Veracity* und *Value* entscheidend für die Extraktion verwertbaren Wissens aus Daten [vgl. Luengo et al. 2020, S.1]. Daten stellen dabei nicht per se einen Mehrwert dar, sondern entfalten diesen erst durch die Identifikation bislang unbekannter Muster und Zusammenhänge [vgl. Triguero et al. 2019, S.2]. Die Qualität der Daten kann anhand verschiedener Dimensionen beschrieben werden, darunter Zugänglichkeit, Konsistenz, Vertraulichkeit, Richtigkeit, Abstammung, Lesbarkeit, Echtzeitfähigkeit, Einzigartigkeit,

Glaubwürdigkeit, Genauigkeit und Vollständigkeit [vgl. Ramasamy und Chowdhury 2020, S.9-10].

Vor diesem Hintergrund wird nach *Triguero et al. (2019)* deutlich, dass Big-Data-Anwendungen in der Praxis sowohl mit der Herausforderung großer Datenmengen und hoher Verarbeitungsgeschwindigkeiten als auch mit häufig unzureichender Datenqualität konfrontiert sind. Daraus ergibt sich die Notwendigkeit, aus der verfügbaren Datenmenge gezielt qualitativ hochwertige und anwendungsrelevante Teilmengen zu extrahieren. Dieses Konzept wird als Smart Data bezeichnet und zielt darauf ab, Daten in einer Form bereitzustellen, die eine effiziente und valide Anwendung von Datenanalysemethoden ermöglicht [vgl. Triguero et al. 2019, S.2]. Neben einer verbesserten Analysefähigkeit führt dieser Ansatz auch zu einer Reduktion von Speicher- und Verarbeitungskosten. Der eigentliche Wert von Daten entsteht dabei erst nach geeigneten Vorverarbeitungsschritten, die eine Nutzung für analytische Zwecke ermöglichen [vgl. García, Luengo et al. 2014, S.10-11]. Entsprechend liegt der Fokus moderner Datenverarbeitung nicht auf der bloßen Speicherung großer Datenmengen, sondern auf der Generierung von Wissen [vgl. Iafate 2014, S.2].

3.4.2 Data Pipeline - Definition und strategische Ansätze

Die technische Umsetzung von Big- und Smart-Data-Konzepten erfordert eine klar definierte Data Pipeline. Diese kann analog zu industriellen Produktionsprozessen verstanden werden, bei denen Rohdaten schrittweise verarbeitet und in analysierbare Ergebnisse überführt werden [vgl. Papp et al. 2022, S.113]. Eine Data Pipeline umfasst dabei typischerweise die Erfassung von Rohdaten, deren Verarbeitung und Transformation, die Speicherung in geeigneten Systemen, die analytische Auswertung sowie die Visualisierung der Ergebnisse. Ergänzend sind Orchestrierungs- und Überwachungsmechanismen erforderlich, um einen stabilen und reproduzierbaren Betrieb sicherzustellen [vgl. Crickard 2020, S.11; Ghosh Chowdhury et al. 2020, S.1006; Tardio et al. 2020, S.201601; Ponnuswami et al. 2020, S.2; Aytas 2021, S.1-2; Papp et al. 2022, S.113-114; Taheri et al. 2023, S.164].

In Produktionsumgebungen handelt es sich dabei häufig nicht um statische Datensätze, sondern um kontinuierlich anfallende Datenströme, wodurch zwischen Batch- und Stream-Processing unterschieden wird [vgl. Luengo et al. 2020, S.11; Soni 2023, S.149; Crickard 2020, S.10; Soumaya et al. 2017, S.6 ff. Das et al. 11032014, S.1]. Während Batch-Processing Daten in zeitlich getrennten Intervallen verarbeitet, erfolgt beim Stream-Processing eine nahezu verzögerungsfreie Verarbeitung in Echtzeit. Die Geschwindigkeit einer Data Pipeline lässt sich dabei anhand verschiedener Latenzarten beschreiben, die sich aus datenbasierter Latenz, Analyseprozesslatenz und Entscheidungsprozesslatenz zusammensetzen und gemeinsam die sogenannte Aktionslatenz bilden [vgl. Iafate 2015, S.21-23].

Die in einer Data Pipeline verarbeiteten Daten müssen in Speichersystemen abgelegt werden, die sowohl operative Anforderungen als auch nachgelagerte Analyse- und Machine-Learning-Workloads unterstützen. Datenbanken lassen sich dabei grundlegend als strukturierte Sammlungen miteinander in Beziehung stehender Daten verstehen, die zielgerichtet für spezifische Anwendungszwecke entworfen und betrieben werden [vgl. Elmasri und Navathe 2016, S.35]. Mit steigenden Anforderungen im Kontext von Big Data, insbesondere

hinsichtlich Datenvolumen, Verarbeitungsgeschwindigkeit und Datenvielfalt (*Volume, Velocity, Variety*), ergeben sich unterschiedliche Speicheransätze, die je nach Datenstruktur und Nutzungsschwerpunkt variieren [vgl. Philip Chen und C.-Y. Zhang 2014, S. 319–321; vgl. Janssen et al. 2024, S.310; vgl. Lu et al. 2018, S. 285–286]. Für strukturierte, konsolidierte Analysen wurden Data-Warehouse-Konzepte entwickelt, die Daten aus verschiedenen Quellen integrieren und historisieren, um Reporting- und Entscheidungsprozesse zu unterstützen [vgl. Kimball und Ross 2002, S. 1–3; vgl. Inmon 2002, S.31-35]. Demgegenüber adressieren Data-Lake-Ansätze insbesondere die Speicherung großer, heterogener Datenbestände in unterschiedlichen Strukturierungsgraden und bilden damit eine Grundlage für explorative Analysen und datengetriebene Verfahren [vgl. H. Fang 2015, S. 820–821; vgl. Khine und Z. S. Wang 2018, S. 2–4]. Neuere Lakehouse-Konzepte verfolgen das Ziel, Eigenschaften beider Ansätze zu kombinieren, ohne dass hieraus eine Festlegung für die im Rahmen dieser Arbeit betrachtete Technologieausprägung abgeleitet wird [vgl. Armbrust et al. 2021, S. 3–5; vgl. Shiyal 2021, S. 32–33]. Insgesamt verdeutlichen diese Entwicklungen die Notwendigkeit, Speicherkonzepte in Data Pipelines flexibel an Datenformate und Analyseanforderungen anzupassen.

Die technische Umsetzung von Data Pipelines kann grundsätzlich Cloud-basiert, On-Premise oder hybrid erfolgen [vgl. Wierse und Riedel 2017, S.383-400; Hentschel und Leyh 2018, S.4-5]. Cloud-basierte Ansätze bieten hohe Skalierbarkeit und Flexibilität, sind jedoch mit Abhängigkeiten hinsichtlich Sicherheit und laufender Kosten verbunden. On-Premise-Lösungen ermöglichen eine hohe Kontrolle über Daten und Infrastruktur, sind jedoch häufig kostenintensiv und nur begrenzt skalierbar. Hybridansätze kombinieren beide Modelle, erhöhen jedoch die Komplexität der Systemarchitektur.

3.5 Einordnung der theoretischen Grundlagen

Die dargestellten theoretischen Grundlagen zu Instandhaltung, Anlagendokumentation, Datenanalyse und Data Pipelines bilden eine fundierte Basis für datengetriebene Produktions- und Instandhaltungskonzepte. In der praktischen Umsetzung zeigen sich jedoch deutliche Herausforderungen. Insbesondere die Integration moderner Instandhaltungsstrategien erfordert erhebliche technische, organisatorische und personelle Ressourcen, die in vielen Unternehmen noch nicht in ausreichendem Maße vorhanden sind [vgl. Gutsche und Voigt 2018, S.164; Velmurugan und Dhingra 2021, S.54-57; Ippolito et al. 2021, S.9-11; Apel 2018, S.66].

Die Digitalisierung technischer Dokumentationen und der Übergang zu durchgängigen, digitalen Lebenszyklusmodellen sind zwar notwendig, gehen jedoch mit Herausforderungen wie Datenmigration, IT-Sicherheit und Standardisierung einher [vgl. Hudetz und Friedewald 2002, S.67-68; E. Schulz und Pflaum 2021, S.52; Gausemeier 2013, S.103]. Gleichzeitig gewinnen unstrukturierte Daten, insbesondere Textdaten, zunehmend an Bedeutung für datenbasierte Wissensgenerierung [vgl. Sturm 2021, S.129-133].

Auch im Bereich der Datenanalyse bestehen trotz ausgereifter theoretischer Konzepte weiterhin Defizite in der praktischen Anwendung. Die erfolgreiche Nutzung von Data-Science- und KI-Methoden setzt neben technischer Expertise ein tiefes Prozessverständnis voraus, insbesondere in dynamischen Produktionsumgebungen [vgl. Nitsche et al. 2021,

S.54-55; Quix 2021, S.86-87; Mockenhaupt 2021, S.227-235]. Darüber hinaus erfordert der Umgang mit großen, heterogenen Datenmengen eine strategisch geplante Data Pipeline sowie eine enge Koordination zwischen technischen und organisatorischen Einheiten [vgl. Holland 2020, S.12; Aho et al. 2020, S.154-155; Helu et al. 2020, S.386].

Aus diesen Beobachtungen ergibt sich ein klarer Handlungsbedarf hinsichtlich der Entwicklung integrierter Dateninfrastrukturen und methodischer Ansätze zur Nutzung von Künstlicher Intelligenz in der Instandhaltung. Insbesondere im Kontext von Condition Monitoring, Predictive Maintenance und Knowledge Based Maintenance wird deutlich, dass erst das Zusammenspiel aus geeigneter Datenbasis, leistungsfähiger Data Pipeline und geeigneten Analyseverfahren eine praxistaugliche Umsetzung ermöglicht. Der daraus resultierende Forschungsbedarf sowie die Wechselwirkungen der betrachteten Konzepte werden im folgenden Kapitel systematisch abgeleitet.

4 Forschungsstand zur datengetriebenen Instandhaltung

Das systematische Darstellen sowie kritische Reflektieren des aktuellen Wissens- und Forschungsstandes im Themenfeld der datengetriebenen Instandhaltungsstrategien ist essentiell zur Darlegung einer konkreten Forschungslücke. Dabei werden einschlägige wissenschaftliche Arbeiten sowie relevante technologische und methodische Ansätze strukturiert aufgearbeitet, um bestehende Erkenntnisse, theoretisches Wissen und praktische Anwendungen zu erfassen. Durch die kritische Analyse der vorhandenen Literatur werden bestehende Limitationen, Widersprüche und bislang unzureichend adressierte Aspekte herausgearbeitet. Auf dieser Basis dient das **Kapitel 2.5.1** der Identifikation einer Forschungslücke. Daraus ableitend werden in **Kapitel 4.2** die Forschungsfragen und die wissenschaftliche Relevanz der vorliegenden Arbeit aufgezeigt.

4.1 Systematische Literaturanalyse

Dieses Unterkapitel stellt die Ergebnisse der systematischen Literaturrecherche dar, die auf der in **Kapitel 2.5.1** beschriebenen methodischen Vorgehensweise basiert. Ziel ist es, den bestehenden Forschungsstand zu datengetriebenen Instandhaltungsstrategien strukturiert aufzubereiten, inhaltlich einzuordnen und kritisch zu reflektieren. Im Fokus stehen dabei nicht die einzelnen Schritte der Recherche, sondern die inhaltlichen Erkenntnisse, die aus der systematischen Analyse der identifizierten Literatur gewonnen werden.

Im Folgenden werden die relevanten Arbeiten zunächst konzeptuell eingeordnet und thematisch strukturiert. Anschließend erfolgt eine inhaltliche Analyse und vergleichende Betrachtung der identifizierten Beiträge, die durch eine ergänzende Abgrenzung bestehender Ansätze vertieft wird. Diese querdimensionale Analyse bildet die Grundlage für die Identifikation von Forschungslücken und bereitet somit die Ableitung der Forschungsfragen vor. Die in diesem Kapitel vorgenommene Analyse folgt damit dem Ziel, den aktuellen Stand der Forschung nicht nur zusammenfassend darzustellen, sondern ihn im Hinblick auf bestehende Defizite, offene Fragestellungen und Gestaltungspotenziale systematisch zu durchdringen.

4.1.1 Rahmen und Umfang der Arbeit

Die im Folgenden dargestellte Einordnung des Rahmens und Umfangs des Forschungsstands basiert auf (I) der in **Kapitel 2.5.1** beschriebenen methodischen Vorgehensweise zur Durchführung der Literaturanalyse. Zur inhaltlichen Kontextualisierung und transparenten Lesart der Ergebnisse wird die Taxonomie von *Cooper (1988)* herangezogen. **Abbildung 9** visualisiert die Ausprägungen zentraler Charakteristika der Literaturübersicht und dient als Orientierungsrahmen für die nachfolgende Analyse der Forschungsbeiträge.

Der **Fokus** des dargestellten Forschungsstands liegt mit stärkerer Gewichtung auf Methoden und Anwendungen datengetriebener Instandhaltungsstrategien, während Forschungsergebnisse ergänzend berücksichtigt werden. Das **Ziel** der Literaturübersicht definiert sich aus den Kategorien der Integration sowie der Identifikation zentraler Problemstellungen. Vor dem Hintergrund heterogener Produktionsumgebungen sowie einer Vielzahl eingesetzter Data-Mining-Methoden ist dabei die Frage der Einordnung und Übertragbar-

keit bestehender Ansätze von besonderer Relevanz. Die **Perspektive** erfolgt durch eine neutrale Position, um die betrachtete Literatur ohne einer voreingenommenen Haltung bewerten zu können. Darüber hinaus wird ein repräsentativer **Abdeckungsgrad** angestrebt, wobei relevante Arbeiten systematisch untersucht und anschließend eine repräsentative Auswahl für das Forschungsfeld definiert wird. Dabei erfolgt die **Organisation** konzeptionell, sodass die Arbeiten und Studien unter Berücksichtigung von thematischen Indikatoren gruppiert werden. Die Literaturübersicht bedient die **Zielgruppen** der spezialisierten Fachleute sowie Praktiker.

Charakteristik	Kategorien			
Fokus	Ergebnisse	Methoden	Theorien	Anwendungen
Ziel	Integration	Kritische Analyse	Identifikation zentraler Problemstellungen	-
Perspektive	Neutrale Position	Kritische Position	-	-
Abdeckungsgrad	Vollständig	Vollständig selektiv	Repräsentativ	Selektiv
Organisation	Historisch	Konzeptionell	Methodische Darstellung	-
Zielgruppe	Fachleute	Spezialisierte Fachleute	PraktikerInnen	Allgemeine Öffentlichkeit

Abbildung 9: Taxonomie der Literaturrecherche für die vorliegende Arbeit

4.1.2 Konzeptualisierung des Themas

Die thematische Strukturierung des im Folgenden dargestellten Forschungsstands erfolgt auf Grundlage der in **Kapitel 2.5.1** beschriebenen methodischen Vorgehensweise (**II**) zur Konzeptualisierung und Festlegung zentraler Schlüsselbegriffe. Die dort entwickelte konzeptionelle Beschreibung dient als begrifflicher Bezugsrahmen für die in diesem Kapitel vorgenommene Analyse und Einordnung der wissenschaftlichen Beiträge. Zur inhaltlichen Orientierung und transparenten Darstellung der relevanten Themenfelder wird in **Abbildung 10** eine Konzept-Map herangezogen, welche zentrale Begriffe sowie deren Beziehungen zueinander visualisiert. Die Darstellung verdeutlicht, dass datengetriebene Instandhaltungsstrategien nicht isoliert zu betrachten sind, sondern sich aus dem Zusammenspiel mehrerer Domänen ergeben. Neben einer separaten Betrachtung einzelner Begriffe, rücken insbesondere deren Schnittstellen in den Fokus. Diese Schnittstellen können sowohl paarweise als auch in der Kombination mehrerer Konzepte auftreten und bilden den thematischen Rahmen für die nachfolgende Analyse des Stands der Forschung. Die Konzept-Map dient damit als inhaltlicher Orientierungsrahmen zur Strukturierung der folgenden Literaturbetrachtung.




Abbildung 10: Konzept-Map für die Literaturrecherche

4.1.3 Literaturrecherche und Identifikation relevanter Autoren

Die Auswahl der in diesem Kapitel betrachteten wissenschaftlichen Beiträge basiert auf der in **Kapitel 2.5.1** beschriebenen systematischen Literaturrecherche (**III**). Die dort definierte Such- und Selektionslogik bildet die Grundlage für die nachfolgende inhaltliche Einordnung des Forschungsstands. Die berücksichtigten Publikationen wurden ausschließlich anhand englischsprachiger Suchbegriffe identifiziert, um eine internationale Perspektive sicherzustellen und qualitativ hochwertige, im internationalen Diskurs verankerte Forschungsarbeiten zu berücksichtigen.

Die identifizierten Arbeiten lassen sich in die in **Kapitel 4.1.2** dargestellten Themenfelder **Produktion** (P), **Informationstechnologie** (IT), **Data Science** (DS), **Trendthemen** (TT), **Anlagendokumentation** (AD) sowie **Instandhaltung** (IH) einordnen. Diese thematische Strukturierung ermöglicht eine gezielte Analyse der Literatur im Hinblick auf datengetriebene Instandhaltungsstrategien sowie deren Einbettung in industrielle Produktionsumgebungen. Die Zuordnung der Beiträge zu den einzelnen Themenfeldern dient der transparenten Darstellung inhaltlicher Schwerpunkte und Abgrenzungen und basiert auf den in **Kapitel 3** dargestellten theoretischen Grundlagen sowie der domänenspezifischen Einordnung des Forschungsfeldes.

Tabelle 4 gibt einen Überblick über die verwendeten englischsprachigen Suchbegriffe und die resultierenden Trefferzahlen in den betrachteten Themengebieten. Die Darstellung verdeutlicht die Breite und Heterogenität des untersuchten Forschungsfeldes und dient als Orientierung für die thematische Eingrenzung der Literatur, ohne eine quantitative Bewertung einzelner Begriffe vorzunehmen.

Zur systematischen Eingrenzung der Literatur und zur Abbildung thematischer Relationen zwischen den Schlagwörtern wird eine Suchstrategie auf Basis boolescher Operatoren (*AND*, *OR*) angewendet. Die Verwendung von *AND* ermöglicht die Identifikation von Schnittmengen zwischen Begriffen, während *OR* der Erweiterung des Suchraums durch die Einbeziehung semantisch verwandter Begriffe dient [vgl. Atkinson und Cipriani 2018, S.79]. Der mittels dieser Suchtechnik aufgestellte Suchalgorithmus ist in **Anhang B** zu sehen. Dem in **Kapitel 2.5.1** definierten Suchprozess folgend wurden ausschließlich wissenschaftliche Arbeiten berücksichtigt, die einen relevanten Erkenntnisbeitrag zum Forschungsfeld leisten. Die weitere Analyse konzentriert sich dabei auf qualitativ hochwertige Publikationen, die nach Sichtung von Titeln, Abstrakta und, bei inhaltlicher Relevanz, vollständigen

Tabelle 4: Schlagwortsuche für die Literaturrecherche

Themengebiet	Englische Suchbegriffe	Google Scholar	ScienceDirect	IEEE Xplore	Summe
Produktion	production	8.250.000	1.000.000	260.018	9.510.018
	production machine	25.800	4.826	1.059	31.685
	process integration	269.000	25.182	1.690	295.875
Trendthemen	industrial internet of things	162.000	5.598	11.615	22.816
	digital transformation	660.000	24.014	8.046	692.060
	smart factory	67.900	5.570	4.729	78.199
	smart maintenance	6.350	538	94	6.982
	industry 4.0	773.000	27.694	11.427	812.121
	smart sensors	186.000	12.780	4.216	202.996
Instandhaltung	maintenance strategies	195.000	16.196	1.104	212.300
	condition monitoring	572.000	27.971	20.024	619.995
	predictive maintenance	165.000	15.553	8.169	188.722
	prescriptive maintenance	2.370	263	27	2.660
	knowledge based maintenance	864	259	9	1.132
Anlagendokumentation	technical documentation	150.000	5.243	1.978	157.221
	digital twin	270.000	23.448	14.697	308.145
Informationstechnologie	database	7.600.000	1.000.000	172.040	8.772.040
	it architecture	34.300	1.000.000	183	1.034.483
	data pipeline	34.000	2.907	920	37.827
Data Science	data mining	6.000.000	126.664	138.875	1.854.645
	data preprocessing	467.000	66.632	8.338	541.970
	machine learning	4.090.000	476.399	360.512	4.926.911
	deep learning	2.850.000	242.014	254.872	3.346.886
	text mining	723.000	23.112	9.059	755.171

Texten als einschlägig bewertet wurden. Die so identifizierten Arbeiten sind in **Tabelle 20** zusammengefasst und den jeweiligen Themenfeldern zugeordnet, wobei „x“ eine inhaltliche Zuordnung und „-“ eine fehlende thematische Relevanz kennzeichnet.

Die im **Anhang C** in der **Tabelle 20** aufgeführten Publikationen bilden den Kernbestand der Literatur, der als Ausgangsbasis für die vertiefende Analyse des Forschungsstands in den folgenden Abschnitten dient. Auf dieser Grundlage werden bestehende Ansätze systematisch eingeordnet und offene Fragestellungen im Sinne des identifizierten Forschungsbedarfs herausgearbeitet.

4.1.4 Forschungsbasierte Literaturanalyse und Forschungsbedarf

Aufbauend auf der Identifikation relevanter wissenschaftlicher Beiträge und deren thematischer Zuordnung erfolgt im Folgenden die inhaltliche Analyse und Einordnung des Forschungsstands gemäß **IV** der in **Kapitel 2.5.1** dargelegte Methodik. Die betrachteten Arbeiten werden dabei systematisch im Hinblick auf ihre Konzepte, Methoden und Beiträge zu datengetriebenen Instandhaltungsstrategien untersucht. Ziel dieser Analyse ist eine strukturierte vergleichende Betrachtung der identifizierten Forschungsbeiträge, um zentrale Gemeinsamkeiten, Unterschiede und wiederkehrende Muster im Forschungsfeld herauszuarbeiten. Auf dieser Basis erfolgt eine inhaltliche Synthese der bestehenden Forschung, die als Grundlage für die Identifikation dominierender Ansätze, zentraler Konzepte sowie bestehender Forschungslücken dient.

Das Themengebiet der **IH-Strategie** wird durch die bereits in der **Abbildung 7** angedeuteten Instandhaltungsstrategien **Condition Monitoring (CM)**, **Predictive Maintenance (PM)**, sowie **Knowledge Based Maintenance (KBM)** eingegrenzt, wobei die Thematik der präskriptiven Instandhaltung in die Kategorie KBM verortet wird. Je nach Instandhaltungsstrategie werden zum einen unterschiedliche Datengrundlagen gefordert

und zum anderen verschiedene Analyseperspektiven eingenommen. Folglich wird mit der **AD** eine weitere Datenquelle herangezogen, die weitere Informationen liefern. Dieses Themengebiet wird klassifiziert durch die **Technische Anlagendokumentation** (TAD), die **Digitale Lebenslaufakte** (DLA) und den **Digitaler Zwilling** (DZ). Darüber hinaus wird das Themengebiet der **IT** durch die **Infrastruktur** (I), die **Datenbank** (DB) sowie die **Kommunikation** (K) kategorisiert. Diese Unterteilung dient der näheren Analyse im Hinblick auf die generellen Bestandteile der Infrastruktur zur Anwendung der Datenanalysemethoden. In Anbetracht dessen wird das Themengebiet der **DS** mit einem breiteren Spektrum betrachtet. Dazu wird unterschieden zwischen **Statistische Methoden** (SM), **Supervised Learning** (S), **Unsupervised Learning** (US), **Machine Learning** (ML) sowie **Deep Learning** (DL). Zudem wird der Aspekt der **Datenvorverarbeitung** (DV) sowie die Ergebnisvisualisierung der Datenanalyse durch **Visualisierung Ergebnisse** (VE) betrachtet. Darüber hinaus werden die betrachteten Arbeiten durch die Kategorien **Datenmenge klein** (DMK) und **Datenmenge groß** (DMG) in Hinblick auf die Menge der Daten näher analysiert. Dabei werden Arbeiten mit Daten, die über mehrere Zyklen und Wochen und/oder einem Datensatz von mehr als 100.000 Datenpunkten der Kategorie DMG zugeordnet. Andernfalls, oder in Arbeiten, in denen die Datenmenge nicht genau beschrieben ist, erfolgt eine Kategorisierung in DMK. Des Weiteren werden die Arbeiten auf den Anwendungsbereich hin untersucht. Die Klassifizierung erfolgt hier durch die **Anwendung auf Produktionsdaten** (APD), die **Anwendung auf Realdaten** (ARD) sowie durch **Simulierte Daten** (SD). Ergänzt wird die Betrachtung der Anwendungsbereich durch die Prüfung, ob verschiedene Datenquellen verwendet wurden. Diese Kategorie ist abgebildet durch **Anwendung auf verschiedene Datenquellen** (AVD). Insgesamt ergibt sich die Eingrenzung der jeweiligen Themengebiete durch die Aktualität der Themen, der Relevanz für das Forschungsvorhaben sowie dem Nutzen zur Darlegung der Forschungsbedarfs. Die Zuordnung der relevanten Autoren in die jeweiligen Kategorien ist in der **Tabelle 21** im **Anhang C** in Form der zuvor beschriebenen Konzeptmatrix zu sehen. Insgesamt lassen sich 74 der betrachteten Autor der Kategorie IH-Strategien zuordnen. Innerhalb dieser Gruppe befassen sich sieben Arbeiten ausschließlich mit CM, 23 mit PM und zehn mit KBM. Eine Analyse der Schnittmengen zeigt, dass 14 Arbeiten sowohl CM als auch PM behandeln, während sechs Arbeiten PM und KBM adressieren. Eine Überschneidung von CM und KBM konnte hingegen nicht identifiziert werden. Darüber hinaus beschäftigen sich 12 Arbeiten mit sämtlichen betrachteten IH-Strategien. Eine weitere inhaltliche Verdichtung ergibt sich durch die Verbindung mit dem Themenfeld AD, wobei 36 Arbeiten einen expliziten Bezug zwischen AD und IH-Strategien aufweisen, während lediglich vier Arbeiten aus dem Bereich AD ohne Bezug zu IH-Strategie verbleiben. Für die Kategorie DLA konnte in der Konzeptmatrix kein Treffer in Verbindung mit dem Suchalgorithmus festgestellt werden. Das Themengebiet IT umfasst 67 Arbeiten, von denen 54 zugleich der IH-Strategie zugeordnet sind. Eine multidimensionale Betrachtung zeigt zudem, dass 29 Arbeiten gleichzeitig in den Kategorien IH-Strategie, AD und IT verortet sind. Ähnliches gilt für das Themenfeld DS, in dem 72 Arbeiten klassifiziert wurden, wovon 60 zugleich der IH-Strategie zugeordnet sind. Mit Blick auf die Anwendungsbereiche ergibt die Analyse, dass sich 31 Arbeiten mit APD, 19 mit ARD und sieben mit SD befassen. Zudem

lassen sich 20 Studien der Kategorie AVD zuordnen. Auffällig ist hierbei, dass Arbeiten aus dem Bereich CM keine Zuordnung zu AVD aufweisen. Dies korrespondiert mit der in **Kapitel 3.1.3** dargestellten Erkenntnis, dass CM maßgeblich auf Messgrößen basiert, die durch Sensorik erfasst werden, wodurch die Variation der Datentypen eingeschränkt ist. Darüber hinaus klassifiziert die Konzeptmatrix 29 Arbeiten in die Kategorie DMK und 13 in DMG. Diese Zuordnungen werden durch eine detaillierte Analyse der jeweiligen Studien gestützt, wobei die theoretischen Grundlagen der Kategorien in der vorliegenden Arbeit an anderer Stelle umfassend erläutert sind. Die hier vorgenommene Betrachtung dient folglich der analytischen Einordnung der relevanten Arbeiten in Bezug auf ihre Kernaussagen, um daraus die zugrunde liegende Forschungslücke abzuleiten.

Die Analyse des aktuellen Forschungsstandes zeigt, dass zahlreiche Arbeiten wesentliche Fortschritte in der Entwicklung von Predictive- und Prescriptive-Maintenance-Ansätzen sowie in der Gestaltung von Data-Pipeline-Architekturen leisten, diese jedoch fragmentiert bleiben und keine ganzheitliche Lösung für die systematische Umsetzung präskriptiver Instandhaltungsstrategien bieten. So heben *Ahmad und Kamaruddin (2012)* hervor, dass klassische Strategien wie *time-based maintenance* oder *condition-based maintenance* zwar weit verbreitet sind, jedoch ineffizient bleiben oder hohe Anforderungen an Sensorik und Datenqualität stellen, während eine echte Entscheidungsunterstützung ausbleibt. *Ferreiro et al. (2016)* sowie *Uhlemann et al. (2017)* verdeutlichen, dass Predictive Maintenance im Kontext von Industrie 4.0 und digitale Zwillinge erhebliche Potenziale entfalten, zugleich aber durch fehlende Integration in bestehende IT-Architekturen und die mangelnde Überführung in präskriptive Handlungsempfehlungen limitiert sind. Auch *Schmidt und Wang (2016)* sowie *Aremu et al. (2018)* adressieren die Herausforderungen der Datenintegration und -strukturierung für ML-gestützte Instandhaltungsstrategien, bleiben jedoch konzeptionell und vernachlässigen die Automatisierung präskriptiver Entscheidungen. *Klein et al. (2025)* argumentieren zwar, dass die Kombination von datengetriebener Anomalieerkennung mit Knowledge Graphs die Interpretierbarkeit deutlich verbessern kann, zeigen aber zugleich, dass die Skalierbarkeit und systematische Integration dieser Ansätze in durchgängige Pipelines bislang nicht gewährleistet ist. *Butte et al. (2018)* und *Shi et al. (2019)* zeigen zwar das Potenzial von Deep Learning Methoden für Prognosen und Diagnosen, beschränken sich jedoch auf spezifische Anwendungsfälle und vernachlässigen die Integration in skalierbare Pipeline-Architekturen. Ähnlich zeigen *Mehdiyev et al. (2017)*, dass LSTM-Autoencoder eine präzise Defekterkennung im Stahlguss ermöglichen, betonen jedoch zugleich die Einschränkung, dass ihre Lösung nicht in reale industrielle Data Pipeline-Architekturen eingebettet ist. *Zekveld und Hancke (2018)* erreichen mit eingebetteten ML-Systemen zur Vibrationsüberwachung zwar eine hohe Genauigkeit auf Sensorknotenebene, zeigen jedoch keine skalierbare Architektur zur industriellen Integration. Auch *Morselli et al. (2021)* präsentieren einen Ansatz zur Anomalieerkennung, vernachlässigen aber die infrastrukturelle Anbindung an produktionsnahe Systeme. Mit dem *prescriptive maintenance model* (PriMa) schlagen *Ansari et al. (2019)* ein Rahmenwerk für präskriptive Instandhaltung in cyber-physischen Systemen (CPPS) vor, das konkrete Handlungsempfehlungen liefert und industrielle Wirksamkeit demonstriert. Gleichwohl weisen die Autoren selbst auf die hohen Herausforderungen bei der Integration multimodaler Datenquellen sowie die

Limitierungen in der Skalierbarkeit und semantischen Automatisierung hin, wodurch die Notwendigkeit einer generischen Data Pipeline untermauert wird. Ähnlich zeigen *Nemeth et al. (2018, 2020)* mit dem PriMa-X- und dem KBM-Reifegrad-Modell, dass Konzepte der präskriptiven Instandhaltung zwar theoretisch fundiert und für eine entsprechende Reifegradbewertung geeignet sind, die konkrete technische Operationalisierung jedoch weitgehend aussteht. Darüber hinaus machen mehrere Arbeiten deutlich, dass trotz signifikanter Fortschritte eine Konsolidierung fehlt. *Giacotto et al. (2025)* betonen, dass die Forschung zu präskriptiver Instandhaltung bislang fragmentiert und ohne einheitliches Referenzmodell bleibt, während *Wahab et al. (2024)* im Kontext von Digitaler Zwilling und prädiktiver Instandhaltung hervorheben, dass die Transformation vorausschauender Erkenntnisse in präskriptive Handlungsempfehlungen bislang unzureichend umgesetzt ist. Auch *de Souza und Rocha (2024)* verweisen im Hinblick auf Industry 5.0 auf die zentrale Herausforderung, technologische und organisatorische Faktoren in praxisnahe Modelle zu integrieren. Zudem verdeutlichen die Arbeiten von *Zhong et al. (2023)* und *Mao et al. (2023)* mit Bezug zu prädiktiven und präskriptiven Instandhaltungskonzepten im Zusammenhang mit dem Digitalen Zwilling, dass durch präzise Modelle und stochastische Optimierung erhebliche Effizienzgewinne möglich sind, jedoch die Übertragbarkeit auf verschiedene industrielle Kontexte offen bleibt. *Van Dinter et al. (2023)* entwickeln mit ihrer Referenzarchitektur für prädiktive Instandhaltungssysteme auf Basis von digitalen Zwillingen zwar einen systematischen Ansatz, der konsistente Anwendungsarchitekturen ableitet und in spezifischen Anwendungsfällen umsetzt, allerdings bleibt die Arbeit auf einer konzeptionellen Ebene und adressiert weder die konkrete Integration in skalierbare Data Pipelines noch den Übergang zur präskriptiven Instandhaltungsstrategie. *Bellavista und Mora (2019)* adressieren mit dem IoTwins-Projekt eine hybride Cloud-Edge-Architektur zur Unterstützung verteilter KI-Anwendungen im industriellen IoT-Kontext. Der Fokus liegt auf der Laufzeitverteilung von Trainings-, Inferenz- und Optimierungskomponenten sowie auf der Einhaltung industrieller Anforderungen wie Latenz, Zuverlässigkeit und Datensouveränität. Obwohl die Arbeit architektur- und plattformbezogene Aspekte integriert betrachtet, verbleibt die Darstellung auf einer projektspezifischen Lösungsebene, ohne ein explizit abstrahiertes Referenzmodell bereitzustellen. *Choubey et al. (2020)* präsentieren mit dem HeePMF einen holistischen End-to-End-Ansatz für präskriptive Instandhaltung, der Datenakquisition, prädiktive Modelle und nachgelagerte Entscheidungs- und Ausführungsprozesse integriert betrachtet. Der Fokus liegt auf der Ableitung handlungsorientierter Entscheidungen aus prädiktiven Analysen, um ungeplante Stillstände zu minimieren und Instandhaltungskosten zu optimieren. Das Framework beschreibt eine mehrschichtige Systemarchitektur sowie Datenflüsse zwischen lokalen und zentralen Entscheidungseinheiten, wobei die Darstellung primär domänenspezifisch und funktionsorientiert bleibt. Eine konkrete Abstraktion im Sinne eines allgemeingültigen Referenzmodells, das Architektur-, Datenpipeline- und Plattformaspekte systematisch trennt und vergleichbar macht, wird nicht vorgenommen. Im Kontext intelligenter Fertigungssysteme stellen *Anton et al. (2020)* einen cloud-basierten Digital-Twin-Ansatz zur Integration von Robotern vor, bei dem virtuelle Repräsentationen physischer Roboter mit cloudseitigen Analyse-, Steuerungs- und Integrationsdiensten verknüpft werden. Der digitale Zwilling fungiert dabei als vermittelnd-

de Abstraktionsebene, über die Konfiguration, Überwachung und Interoperabilität heterogener Robotersysteme realisiert werden. Der Fokus der Arbeit liegt auf der praktischen Einbindung robotischer Systeme in cloudgestützte Produktionsumgebungen. Eine weitergehende Abstraktion zu einem domänenübergreifenden Referenzmodell, das Architektur-, Datenpipeline- und Plattformaspekte systematisch trennt und vergleichbar macht, ist jedoch nicht Gegenstand der Untersuchung. Vor dem Hintergrund industrieller Instandhaltungsprozesse entwickeln *Kohl et al. (2021)* eine modulare Architektur für kognitive Wartungssysteme, die die Integration unterschiedlicher Datenquellen sowie KI-gestützter Analyse- und Entscheidungsfunktionen vorsieht. Die ARCHIE-Architektur ist dabei konzeptionell so ausgelegt, dass sowohl strukturierte Maschinendaten als auch unstrukturierte Informationsquellen berücksichtigt werden können. In den vorgestellten Anwendungsfällen liegt der Fokus jedoch primär auf der Verarbeitung unstrukturierter Textdaten aus Wartungs- und Schichtberichten, die zur Ableitung von Kompetenzen, Handlungsempfehlungen und Kennzahlen genutzt werden. Eine gleichwertige empirische Demonstration einer multimodalen Datenpipeline oder einer durchgängigen Plattformintegration bleibt damit auf die Architekturbeschreibung beschränkt. Mit Blick auf Predictive Maintenance im industriellen Umfeld formulieren *Uhlmann et al. (2021)* ein holistisches Konzept inklusive einer Referenzarchitektur, das Sensorik, Edge Computing, digitale Zwillinge und cloud-basierte Analysedienste integriert. Die vorgeschlagene Architektur orientiert sich an etablierten IIoT-Modellen und beschreibt eine durchgängige Datenpipeline von der physischen Ebene über Netzwerk- und Edge-Komponenten bis hin zu Anwendungs- und Plattformdiensten, wobei explizit heterogene Datenquellen berücksichtigt werden sollen. In der experimentellen Umsetzung konzentriert sich die Arbeit jedoch primär auf vibrationsbasierte Sensordaten aus einem spezifischen Testaufbau, die zur Zustandsklassifikation und RUL-Prognose genutzt werden. Weitere im Architekturkonzept vorgesehene Datenquellen, etwa aus Wartungshistorien oder digitalen Assistenzsystemen, werden lediglich perspektivisch adressiert. Damit bleibt die Referenzarchitektur zwar klar strukturiert und formal benannt, ihre vollständig integrierte, multimodale Realisierung wird jedoch nicht umfassend empirisch demonstriert. In Bezug auf datengetriebener Produktionsumgebungen entwickeln *Süve et al. (2021)* ein Predictive-Maintenance-Framework auf Basis digitaler Zwillinge, das die kontinuierliche Zustandsüberwachung von Anlagen mit simulations- und analyse-gestützten Vorhersagemodellen verbindet. Der digitale Zwilling fungiert dabei als zentrales Bindeglied zwischen physischem Produktionssystem und analytischer Auswertung, um Wartungsentscheidungen frühzeitig und zustandsbasiert zu unterstützen. Die vorgeschlagene Lösung adressiert eine durchgängige Datenverarbeitungskette von der Datenerfassung über Modellierung und Analyse bis hin zur Entscheidungsunterstützung. In der praktischen Ausgestaltung liegt der Schwerpunkt jedoch auf maschinennahen Zustands- und Prozessdaten, während weitere potenziell relevante Datenquellen nur randständig berücksichtigt werden. Entsprechend bleibt das Framework trotz seines ganzheitlichen Anspruchs primär anwendungsorientiert, ohne als abstraktes, vergleichbares Referenzmodell formalisiert zu werden. Die Arbeit von *Fortoul-Díaz et al. (2023)* stellt eine umfassende Smart-Factory-Architektur auf Basis von Industrie-4.0-Technologien vor, die explizit auf eine durchgängige Integration von Cyber-Physical Systems, Edge Computing, Cloud Computing, Data Ana-

lytics, künstlicher Intelligenz und Cybersecurity abzielt. Besonderes Merkmal ist der konsequente Einsatz von Open-Source-Software sowie die detaillierte Beschreibung der einzelnen Architekturelemente und ihrer Wechselwirkungen. Im Unterschied zu vielen konzeptionellen Arbeiten wird die Architektur in einem realen Pilot-Szenario umgesetzt und validiert. Anhand einer Fallstudie mit Unterstützung eines digitalen Zwillings werden sowohl Datenflüsse über mehrere Ebenen als auch KI-gestützte Entscheidungsmechanismen demonstriert. Damit deckt der Ansatz mehrere Schichten ab, die in der Literatur häufig isoliert betrachtet werden. Gleichzeitig zeigt sich, dass die Architektur stark use-case-getrieben ist: Die konkrete Ausgestaltung, insbesondere hinsichtlich Datenarten, Modellkopplung und Wiederverwendbarkeit der Referenzstruktur, bleibt eng an das demonstrierte Szenario gebunden. Eine systematische Abstraktion zu einem domänenübergreifend einsetzbaren Referenzmodell wird nur begrenzt vorgenommen. Damit leistet die Arbeit einen wichtigen Beitrag zur praktischen Umsetzbarkeit ganzheitlicher Smart-Factory-Architekturen, lässt jedoch offen, wie ein solches Architekturkonzept unabhängig vom konkreten Anwendungsfall als generisches Referenzmodell operationalisiert werden kann. Vor dem Hintergrund wachsender Komplexität digitaler Zwillinge schlagen *dos Santos et al. (2024)* eine hybride Architektur vor, die Edge- und Cloud-Komponenten kombiniert, um Echtzeitfähigkeit, Skalierbarkeit und Rechenflexibilität miteinander zu verbinden. Der Ansatz adressiert explizit die Verteilung von Datenverarbeitung und Modelllogik zwischen lokalen Ressourcen und zentralen Plattformdiensten, um sowohl zeitkritische als auch rechenintensive Aufgaben effizient zu unterstützen. Im Mittelpunkt steht die architektonische Kopplung physischer Systeme, digitaler Zwillinge und analytischer Dienste über mehrere Ebenen hinweg. Die Validierung erfolgt jedoch anhand ausgewählter Anwendungsszenarien, in denen spezifische Datenarten und Interaktionsmuster betrachtet werden. Eine systematische Abstraktion der vorgeschlagenen Hybridarchitektur zu einem generisch anwendbaren Referenzmodell, das Architektur-, Datenpipeline- und Plattformaspekte unabhängig vom Use Case vergleichbar strukturiert, bleibt damit begrenzt. Mit dem Ziel, Optimierungsaufgaben in industriellen Produktionssystemen ganzheitlich zu adressieren, präsentieren *Giacotta et al. (2024)* ein holistisches und skalierbares Framework, das Datenintegration, Analyse, Optimierung und Entscheidungsunterstützung über mehrere Systemebenen hinweg vereint. Der Ansatz ist darauf ausgelegt, unterschiedliche Optimierungsprobleme innerhalb einer gemeinsamen Architektur zu behandeln und dabei skalierbare Rechenressourcen zu nutzen. Die vorgeschlagene Architektur beschreibt eine mehrschichtige Verarbeitungskette, in der Daten aus unterschiedlichen Quellen aggregiert, analysiert und in Optimierungsmodelle überführt werden. Im Vordergrund steht dabei die funktionale Kopplung von Datenanalyse und Optimierungslogik, während Aspekte wie die formale Modellierung einer durchgängigen Datenpipeline oder eine klare Trennung zwischen Architektur-, Plattform- und Referenzmodellebene nur implizit adressiert werden. Entsprechend bleibt das Framework trotz seines ganzheitlichen Anspruchs primär lösungs- und anwendungsorientiert. Die Arbeit von *Weller et al. (2024)* adressiert explizit die Integration von Fallstudien in Bezug auf präskriptiven Analysen in intelligenten Produktionsumgebungen und schlägt dafür eine referenzarchitekturbasierte Lösung vor. Im Mittelpunkt steht weniger ein einzelner Anwendungsfall als vielmehr die systematische Einbettung von Entscheidungslogik, Da-

tenflüssen und bestehenden IT-Systemen entlang der Automatisierungspyramide. Die vorgeschlagene Architektur deckt zentrale Ebenen wie Datenintegration, Analyse-Bausteine und Entscheidungsorchestrierung ab und wird anhand eines realen Demonstrators validiert. Gleichzeitig bleibt der Fokus auf präskriptiver Analyse als Entscheidungsebene, ohne ein domänenspezifisches, durchgängiges Referenzmodell für Datenpipelines, Modelllebenszyklen und Plattformaspekte zu formulieren. Damit liefert die Arbeit wichtige konzeptionelle Impulse, lässt jedoch Raum für eine weitergehende, stärker integrierte Referenzmodellierung. *Abdullahi et al. (2024)* verfolgen das Ziel, bestehende Defizite in der Standardisierung und Skalierbarkeit von digitalen Zwillingen für Predictive Maintenance zu adressieren, und schlagen hierfür ein verteiltes Framework auf Basis einer Edge-Fog-Cloud-Architektur vor. Der Ansatz kombiniert IoT-basierte Datenerfassung, maschinelles Lernen und eine explizit modellierte Rückkopplung zwischen digitalem und physischem Zwilling, um Echtzeitfähigkeit, Vorhersagegenauigkeit und Reaktionsgeschwindigkeit zu verbessern. Im Unterschied zu vielen rein konzeptionellen Arbeiten wird das Framework entlang einer klar strukturierten, mehrschichtigen Architektur detailliert ausgearbeitet und anhand eines realitätsnahen Fallbeispiels aus dem Bereich der Windenergie empirisch untersucht. Dabei liegt der Fokus jedoch auf sensorbasierten Zeitreihendaten einzelner Komponenten sowie auf einer domänenspezifischen Ausprägung des Digital Twins. Trotz expliziter Bezugnahme auf bestehende Standards verbleibt die Ausarbeitung auf der Ebene eines anwendungsnahen Frameworks, ohne ein abstraktes, domänenübergreifend vergleichbares Referenzmodell im engeren Sinne zu formalisieren. Vor dem Hintergrund preskriptiver Instandhaltung adressieren *Ordieres-Meré et al. (2025)* die Herausforderung langfristig stabiler und zuverlässiger Vorhersagemodelle und schlagen ein Framework vor, das kontinuierliche Modellüberwachung, automatisierte Neubewertung und Reinforcement-Learning-basierte Entscheidungsunterstützung integriert. Der Beitrag positioniert sich explizit nicht auf Ebene einzelner Machine-Learning-Algorithmen, sondern auf der Orchestrierung des gesamten Modelllebenszyklus in industriellen Umgebungen. Das Framework beschreibt eine cloud-orientierte Architektur mit klaren Funktionsblöcken für Datenaufbereitung, Modelltraining, Performance-Monitoring, automatisierte Modellaktualisierung sowie Entscheidungsunterstützung. In der praktischen Umsetzung liegt der Fokus jedoch auf einer konkreten Pumpensystem-Fallstudie, bei dem vor allem sensorbasierte Zeitreihendaten verarbeitet werden. Trotz des expliziten Referenzframework-Anspruchs bleibt die Ausgestaltung der Datenpipeline, der Plattformabhängigkeiten und der Übertragbarkeit auf andere Domänen weitgehend anwendungsgetrieben. *Chen et al. (2025)* untersuchen die Konvergenz von Künstlicher Intelligenz und Digital Twins in der Instandhaltung aus einer übergeordneten Perspektive und kombinieren hierzu eine systematische Literaturreview mit qualitativen Industrieinterviews. Ziel der Arbeit ist weniger die Entwicklung eines konkreten technischen Modells als vielmehr die Identifikation struktureller Lücken zwischen akademischer Forschung und industrieller Umsetzung von KI-unterstützten digitalen Zwillingen in der Instandhaltung. Auf Basis der Analyse leiten die Autoren eine fünfschichtige Referenzstruktur ab, die wiederkehrende funktionale Bausteine bestehender Ansätze zusammenführt. Der Mehrwert der Arbeit liegt insbesondere in der expliziten Gegenüberstellung von Forschungsansprüchen und industriellen Realitäten, etwa hinsichtlich Skalierbarkeit, Da-

tenqualität und Modellrobustheit. Gleichzeitig verbleibt die vorgeschlagene Struktur auf einer konzeptionell-synthetisierenden Ebene, wobei Architekturentscheidungen, Datenpipelines, Plattformabhängigkeiten und Referenzmodellgrenzen bewusst nicht formalisiert, sondern als offene Gestaltungsräume adressiert werden. Vor dem Hintergrund datengetriebener Instandhaltung in Industrie-4.0-Umgebungen schlagen *Mallioris et al. (2025)* ein holistisches Framework für prädiktive und präskriptive Wartung vor, das explizit sowohl strukturierte Sensordaten als auch unstrukturierte Wartungsberichte integriert und mittels KI- und NLP-Methoden auswertet. Der Ansatz adressiert operative, taktische und strategische Entscheidungsebenen und verfolgt das Ziel, Wartungswissen systematisch zu strukturieren und in automatisierte Entscheidungsprozesse zu überführen. Die vorgestellte Architektur beschreibt eine mehrstufige Verarbeitungskette von der Erfassung und Aufbereitung heterogener Daten über KI-gestützte Analyse bis hin zu Entscheidungs- und Empfehlungssystemen. In der praktischen Umsetzung liegt der Schwerpunkt jedoch auf einer präskriptiven Fallstudie in einer Molkereiproduktionslinie, wobei insbesondere Textdaten aus Wartungsberichten im Fokus stehen. Sensorbasierte Daten werden überwiegend konzeptionell adressiert, aber nicht gleichwertig integriert. Das Framework verbleibt damit auf der Ebene eines anwendungsnahen Leitmodells, ohne eine formale Abstraktion zu einem domänenunabhängigen, vergleichbaren Referenzmodell vorzunehmen. In Bezug auf hochregulierte pharmazeutische Produktionsumgebungen präsentieren *Parapalli und Shetty (2025)* ein hybrides Edge-Cloud-Framework für prädiktive Instandhaltung, das explizit in ein MES integriert ist und auf Big-Data-Analytik sowie maschinelles Lernen zurückgreift. Ziel des Ansatzes ist es, Echtzeit-Anomalieerkennung auf der Edge-Ebene mit cloudbasierter, skalierbarer Modellbildung zu kombinieren und dadurch den Übergang von reaktiver zu prädiktiver und präskriptiver Instandhaltung zu unterstützen. Die Arbeit beschreibt detailliert eine mehrschichtige Architektur sowie eine eng gekoppelte MES-Integration zur automatisierten Wartungsplanung und Compliance-Dokumentation. Die Validierung erfolgt anhand mehrerer industrieller Fallstudien aus der pharmazeutischen Produktion, die signifikante Reduktionen von Stillstandszeiten und Wartungskosten belegen. Gleichzeitig ist der Ansatz stark domänen- und regulierungsspezifisch ausgeprägt. Architekturentscheidungen, Datenpipeline-Ausgestaltung und Plattformkopplung sind eng an pharmazeutische MES-Systeme und regulatorische Anforderungen gebunden, sodass eine abstrahierte, domänenübergreifend vergleichbare Referenzmodellierung nicht im Fokus steht. Die sich aus der Literaturanalyse ergebende Konzeptmatrix der relevanten Autoren im Forschungsthema, worin die Forschungslücke hervorgehoben wird, ist in der **Abbildung 11** dargestellt.

Zusammenfassend zeigt sich, dass in der aktuellen Forschung eine Vielzahl an Ansätzen existiert, die datengetriebene Instandhaltungsstrategien aus unterschiedlichen Perspektiven adressieren. Die analysierten Arbeiten reichen von architekturbasierten Lösungen über Digital-Twin- und Edge-Cloud-Konzepte bis hin zu holistischen Frameworks für prädiktive und präskriptive Instandhaltung, die teilweise auch aktuelle Themen wie KI, maschinelles Lernen oder die Integration unstrukturierter Daten berücksichtigen. Trotz dieser inhaltlichen Breite bleibt festzustellen, dass die meisten Beiträge entweder stark an konkrete Anwendungsfälle oder spezifische Domänen gebunden sind oder primär konzeptionelle Lösungsansätze verfolgen. Eine explizite, domänenübergreifend abstrahierte Be-




Abbildung 11: Konzeptmatrix der relevanten Autoren im Forschungsthema

trachtung im Sinne eines Referenzmodells für datengetriebene Instandhaltungsstrategien, das Architektur, Datenpipeline, Plattform- und Integrationsaspekte systematisch strukturiert und vergleichbar macht, ist bislang nicht umfassend ausgearbeitet. Die identifizierte Forschungslücke liegt somit weniger in einzelnen methodischen oder technologischen Bausteinen, sondern vielmehr in der fehlenden konsistenten Abstraktion und Abgrenzung bestehender Arbeiten zu einem integrierten Referenzmodell. Um diese Forschungslücke im Detail zu analysieren, werden im folgenden Unterkapitel ausgewählte Arbeiten vertieft betrachtet, die explizite Bezüge zu Datenpipelines, Systemarchitekturen, Plattformkonzepten und referenzmodellnahen Strukturen aufweisen. Auf dieser Basis erfolgt eine systematische Abgrenzung der bestehenden Ansätze und die Ableitung dessen, welchen spezifischen Beitrag das im Rahmen dieser Dissertation entwickelte Artefakt leistet und bewusst nicht leistet.

4.1.5 Systematische Abgrenzung bestehender Arbeiten

Die Analyse des Stands der Forschung in **Kapitel 4.1.4** hat gezeigt, dass eine Vielzahl von Arbeiten existiert, die datengetriebene Instandhaltungsstrategien aus unterschiedlichen Perspektiven adressieren. Die betrachteten Beiträge unterscheiden sich dabei nicht nur hinsichtlich ihres thematischen Fokus, sondern insbesondere im Abstraktionsgrad, in der Rolle von Datenpipelines sowie in der Art und Weise, wie sie in bestehende Produktions- und IT-Infrastrukturen eingebettet sind. Diese Heterogenität erschwert eine direkte Vergleichbarkeit der Ansätze und macht eine explizite Abgrenzung erforderlich. Für die folgende Abgrenzung wird daher nicht die Gesamtheit der in **Kapitel 4.1.4** betrachteten Arbeiten herangezogen, sondern eine gezielte Auswahl solcher Beiträge vorgenommen, die sich für eine referenzmodellorientierte Analyse eignen. Berücksichtigt werden Arbeiten, die über eine rein algorithmische oder lokal begrenzte Fallstudie hinausgehen und explizi-

te Aussagen zu Architekturstrukturen, Datenpipelines, konzeptionellen Frameworks oder referenzmodellnahen Elementen treffen. Reine Methodenbeiträge oder stark spezialisierte Anwendungsstudien ohne übergreifende Strukturierung werden hingegen nicht weiter betrachtet, da sie keinen geeigneten Vergleichsmaßstab für die Ableitung eines Referenzmodells bieten.

Um eine systematische und nachvollziehbare Abgrenzung zu ermöglichen, werden die ausgewählten Arbeiten entlang klar definierter Analyse-Dimensionen betrachtet. Diese Dimensionen dienen nicht der Bewertung einzelner Ansätze, sondern der strukturierten Einordnung ihrer jeweiligen Schwerpunkte und Grenzen. Eine zentrale Dimension ist dabei der Abstraktionsgrad des jeweiligen Beitrags (**Dimension A**). Unterschieden wird zwischen architekturbezogenen Arbeiten, die konkrete Systemstrukturen oder Implementierungen beschreiben, konzeptionellen Frameworks, die funktionale Bausteine lose zusammenführen, und expliziten Referenzmodellen, die eine abstrahierte, vergleichbare Strukturierung anstreben. Eine weitere Dimension betrifft die Ausgestaltung der Datenpipeline (**Dimension B**). Betrachtet wird, inwieweit der Weg von der Datenerfassung über Verarbeitung und Modellierung bis hin zur Nutzung der Modellergebnisse explizit beschrieben wird und ob Rückkopplungsmechanismen vorgesehen sind, über die neue Daten oder Erkenntnisse systematisch in den Prozess zurückgeführt werden. Diese Dimension ist insbesondere relevant, da viele bestehende Arbeiten Datenpipelines lediglich implizit annehmen, ohne sie als eigenständiges Gestaltungselement zu modellieren. Ergänzend dazu wird der Umgang mit Modellverständnis und Ursachenbezug betrachtet (**Dimension C**). Hierbei wird zwischen korrelationsbasierten Ansätzen und solchen unterschieden, die explizit kausale Zusammenhänge adressieren oder zumindest vorbereiten. Von Interesse ist insbesondere, ob Mechanismen vorgesehen sind, um Ursachenwissen systematisch abzuleiten, zu dokumentieren oder über die Zeit weiterzuentwickeln, etwa durch die Einbindung von Domänenexperten oder die Nutzung anlagenspezifischer Dokumentationen. Ein weiterer Abgrenzungaspekt betrifft die Einbettung der betrachteten Ansätze in bestehende Produktions- und IT-Infrastrukturen (**Dimension D**). Analysiert wird, ob und in welchem Umfang Systeme wie MES, CMMS oder ereignisbasierte Datenbanken berücksichtigt werden oder ob die vorgestellten Lösungen von einer idealisierten, neu aufzubauenden Systemlandschaft ausgehen. Gerade für die praktische Übertragbarkeit datengetriebener Instandhaltungsstrategien ist diese Dimension von zentraler Bedeutung. Eine weitere Dimension bezieht sich darauf, in welchem Umfang die betrachteten Arbeiten eine Weiterentwicklung über den ursprünglich adressierten Anwendungsfall hinaus berücksichtigen (**Dimension E**). Analysiert wird dabei, ob Mechanismen zur Wiederverwendung von Modellen, zur Nutzung historischer Ereignisdaten oder zur systematischen Akkumulation von Wissen beschrieben werden. Von besonderem Interesse ist, ob Modellergebnisse, erkannte Ereignisse oder Ursacheninformationen so abgelegt werden, dass sie in nachfolgenden Analyse- oder Entscheidungsprozessen erneut genutzt werden können. Diese Dimension adressiert damit nicht den unmittelbaren Funktionsumfang eines Ansatzes, sondern dessen Fähigkeit, datengetriebene Instandhaltung als evolutionären Prozess zu unterstützen und perspektivisch automatisierte Entscheidungs- oder Handlungsempfehlungen vorzubereiten.

Zur vergleichenden Einordnung der ausgewählten Arbeiten wird in **Tabelle 5** eine

Abgrenzungsmatrix herangezogen, in der die Beiträge entlang der definierten Analyse-Dimensionen systematisch gegenübergestellt werden. Zur Kennzeichnung der Ausprägung einzelner Dimensionen wird eine dreistufige qualitative Notation verwendet. Ein „x“ steht für eine explizite und systematische Adressierung der jeweiligen Dimension. Werden entsprechende Aspekte lediglich implizit, eingeschränkt oder auf konzeptioneller Ebene berücksichtigt, wird dies durch „/“ kenntlich gemacht. Das Symbol „-“ kennzeichnet schließlich, dass die betreffende Dimension nicht oder nur randständig behandelt wird. Im Gegensatz zu den übrigen Analyse-Dimensionen wird der Abstraktionsgrad (**Dimension A**) der betrachteten Arbeiten nicht ordinal, sondern kategorial eingeordnet. Ziel dieser Kategorisierung ist es nicht, eine formale Typologie von Modellen zu entwickeln, sondern die strukturelle Vergleichbarkeit der betrachteten Beiträge im Hinblick auf ihren Abstraktionsanspruch sicherzustellen. Architekturbezogene Arbeiten beschreiben in der Regel konkrete Systemstrukturen, Komponenten oder Implementierungen und sind häufig an spezifische Anwendungsszenarien oder technische Umgebungen gebunden [vgl. Dern 2006, S.18-20]. Konzeptionelle Frameworks fassen funktionale Bausteine, Prozesse oder Methoden zusammen, ohne eine vollständige Abstraktion oder normative Strukturierung anzustreben [vgl. Zachman 1987, S.283-284]. Referenzmodellnahe Arbeiten zeichnen sich durch einen expliziten Strukturierungsanspruch und eine erhöhte Abstraktion aus, verzichten jedoch auf eine formale Ausarbeitung als Referenzmodell [vgl. J. Becker et al. 2007, S.27-29]. Explizite Referenzmodelle hingegen formulieren eine abstrahierte, vergleichbare Struktur, die als Orientierungs- oder Bezugsrahmen für unterschiedliche Anwendungsfälle dienen soll [vgl. Fettke und Loos 2004, S.332-335]. Die Abgrenzungsmatrix dient ausschließlich der strukturierten Einordnung der betrachteten Arbeiten und stellt keine Bewertung im Sinne einer Rangfolge oder Qualitätsaussage dar. Vielmehr bildet sie die Grundlage für die anschließende vertiefte Analyse der identifizierten Gemeinsamkeiten, Unterschiede und strukturellen Grenzen bestehender Ansätze, aus der im weiteren Verlauf die konkrete Forschungslücke abgeleitet wird.

Dimension A - Abstraktionsebene. Die Betrachtung der Abstraktionsebene zeigt eine deutliche Heterogenität der im Forschungsfeld adressierten Beiträge. Ein Großteil der Arbeiten ist entweder als architekturbezogen oder als konzeptionelles Framework einzuordnen. Architekturbezogene Arbeiten fokussieren überwiegend auf konkrete Systemstrukturen, Komponenten oder technische Integrationsszenarien und sind häufig eng an spezifische Anwendungskontexte oder technologische Umgebungen gebunden. Sie leisten damit wichtige Beiträge zur praktischen Umsetzung datengetriebener Instandhaltungsansätze, verbleiben jedoch auf einer system- oder projektspezifischen Ebene. Konzeptionelle Frameworks verfolgen demgegenüber einen stärker abstrahierenden Ansatz, indem sie funktionale Bausteine, Prozessschritte oder analytische Komponenten zusammenführen. Diese Arbeiten zielen primär auf eine strukturierende Darstellung des Lösungsraums ab, verzichten jedoch in der Regel auf eine normative oder vergleichbare Modellstruktur. Entsprechend bleibt ihre Übertragbarkeit auf unterschiedliche Anwendungsfälle eingeschränkt, da weder klare Abgrenzungen noch verbindliche Modellannahmen formuliert werden. Neben diesen beiden Gruppen lassen sich einzelne Arbeiten identifizieren, die als referenzmodellnah einzuordnen sind. Diese Beiträge zeichnen sich durch einen erhöhten Abstraktionsanspruch

Tabelle 5: Abgrenzungsmatrix der betrachteten Arbeiten

Nr.	Autoren (Jahr)	A	B	C	D	E
7	<i>Schneider et al. (2019)</i>	Architektur	x	/	x	x
10	<i>Bellavista et al. (2019)</i>	Architektur	x	–	x	/
16	<i>Lee et al. (2020)</i>	Referenzmodellnah	/	/	/	/
18	<i>Kammerer et al. (2020)</i>	Architektur	x	–	/	–
22	<i>Paolanti et al. (2018)</i>	Architektur	x	/	/	–
27	<i>Sang et al. (2021)</i>	Referenzmodellnah	x	/	x	/
30	<i>Zenkert et al. (2021)</i>	Referenzmodellnah	/	/	/	x
61	<i>Németh et al. (2018)</i>	Referenzmodell	/	/	/	x
63	<i>Ansari et al. (2019)</i>	Referenzmodell	/	/	/	/
79	<i>Bellavista & Mora (2019)</i>	Architektur	/	–	/	–
80	<i>Choubey et al. (2020)</i>	Framework	x	–	/	–
81	<i>Anton et al. (2020)</i>	Architektur	/	–	/	–
82	<i>Kohl et al. (2021)</i>	Framework	/	/	/	–
83	<i>Uhlmann et al. (2021)</i>	Referenzmodell	/	–	/	–
84	<i>Süve et al. (2021)</i>	Framework	/	–	/	–
85	<i>Fortoul-Díaz et al. (2023)</i>	Architektur	x	–	/	–
86	<i>dos Santos et al. (2024)</i>	Architektur	/	–	/	–
87	<i>Giacotta et al. (2024)</i>	Framework	/	–	/	–
88	<i>Weller et al. (2024)</i>	Referenzmodell	/	–	/	–
89	<i>Abdullahi et al. (2024)</i>	Architektur	/	–	/	–
90	<i>Ordieres-Meré et al. (2025)</i>	Framework	x	–	/	/
91	<i>Chen et al. (2025)</i>	Framework	–	/	–	/
92	<i>Mallioris et al. (2025)</i>	Framework	/	/	/	–
93	<i>Parapalli & Shetty (2025)</i>	Architektur	x	–	x	/

und einen expliziten Strukturierungswillen aus, etwa durch die systematische Anordnung von Daten-, Analyse- und Entscheidungsaspekten. Gleichzeitig wird jedoch deutlich, dass diese Arbeiten auf eine vollständige formale Ausarbeitung als Referenzmodell verzichten. Insbesondere bleiben Fragen der Vergleichbarkeit, der Abgrenzung zu konkreten Implementierungen sowie der systematischen Einbettung operativer Prozesse häufig offen. Explizite Referenzmodelle sind im betrachteten Korpus nur vereinzelt vertreten. Diese Arbeiten formulieren zwar eine abstrahierte Struktur und beanspruchen explizit Referenzcharakter, fokussieren sich jedoch überwiegend auf prozessuale, methodische oder reifegradbezogene Aspekte. Die operative Ausgestaltung datengetriebener Instandhaltungsstrategien sowie deren technische und informationelle Konkretisierung werden meist nicht im Detail adressiert.

Zusammenfassend zeigt sich entlang der Abstraktionsebene, dass zwar unterschiedliche Modellierungsansätze existieren, diese jedoch entweder stark an konkrete Systemarchitekturen gebunden sind oder auf einer konzeptionellen Ebene verbleiben. Referenzmodellnahe und explizite Referenzmodelle adressieren zwar einen höheren Abstraktionsgrad, lassen jedoch zentrale Aspekte der operativen Ausgestaltung offen. Die Abstraktionsebene allein erweist sich damit als notwendige, aber nicht hinreichende Grundlage für eine systematische Vergleichbarkeit und Weiterentwicklung datengetriebener Instandhaltungsansätze.

Dimension B - Explizite Datenpipeline. Die Analyse entlang der Dimension der expliziten Datenpipeline verdeutlicht eine ausgeprägte Diskrepanz zwischen konzeptionellem Anspruch und operativer Ausgestaltung in den betrachteten Arbeiten. Zwar wird die Bedeutung datengetriebener Ansätze für die Instandhaltung in nahezu allen Beiträgen hervorgehoben, eine explizite Modellierung der zugrunde liegenden Datenpipeline erfolgt jedoch nur in einem begrenzten Teil der Arbeiten. Architekturbezogene Beiträge adressieren die Datenpipeline häufig implizit, indem sie Datenquellen, Verarbeitungskomponenten

ten und Analysefunktionen benennen. Die Pipeline ergibt sich dabei aus der technischen Anordnung der Systemkomponenten, ohne als eigenständiges Gestaltungselement explizit modelliert zu werden. Entsprechend bleiben Fragen der Datenflüsse, Übergabepunkte, Rückkopplungen und Zustandsübergänge häufig auf einer technischen oder implementierungsnahen Ebene verankert. Konzeptionelle Frameworks beschreiben Datenverarbeitung meist als Abfolge funktionaler Schritte, etwa von der Datenerfassung über Analyse bis hin zur Entscheidungsunterstützung. Diese Darstellung dient primär der Strukturierung des Lösungsraums und nicht der Spezifikation einer durchgängigen, operationalisierbaren Datenpipeline. Insbesondere fehlen häufig Aussagen zur persistierenden Speicherung von Zwischenergebnissen, zur Wiederverwendbarkeit von Daten sowie zur systematischen Rückführung von Analyseergebnissen in nachgelagerte Prozesse. Referenzmodellnahe Arbeiten und explizite Referenzmodelle adressieren Datenverarbeitung in der Regel auf einer prozessualen oder methodischen Ebene. Zwar werden logische Phasen der Datenverarbeitung klar benannt, eine explizite Ausgestaltung der Pipeline als verbindende Struktur zwischen Datenerhebung, Modellbildung, Anwendung und Rückkopplung bleibt jedoch meist offen. Damit wird die Datenpipeline nicht als zentrales Bindeglied zwischen abstraktem Modell und operativer Umsetzung verstanden, sondern als implizite Voraussetzung vorausgesetzt.

Insgesamt zeigt sich, dass die explizite Modellierung einer durchgängigen Datenpipeline in den betrachteten Arbeiten nur punktuell erfolgt. Selbst dort, wo Datenflüsse technisch umgesetzt oder konzeptionell beschrieben werden, fehlt häufig eine abstrahierte, vergleichbare Darstellung der Pipeline als eigenständiges Modellelement. Die Dimension der Datenpipeline erweist sich damit als kritisch für die Übertragbarkeit, Vergleichbarkeit und Weiterentwicklung datengetriebener Instandhaltungsansätze und bildet eine wesentliche Schnittstelle zwischen Modellabstraktion und operativer Umsetzung.

Dimension C - Kausalitäts- und Labelingbezug. Die Analyse der Dimension des Kausalitäts- und Labelingbezugs zeigt, dass dieser Aspekt in den betrachteten Arbeiten nur in sehr begrenztem Umfang systematisch adressiert wird. Zwar wird die Bedeutung von Ursachenverständnis, Fehlerdiagnose oder erklärbaren Ergebnissen in vielen Beiträgen betont, eine explizite Modellierung kausaler Zusammenhänge oder eine strukturierte Ableitung von Trainingslabels bleibt jedoch meist aus. Ein Großteil der Arbeiten folgt implizit einem korrelationsbasierten Paradigma, bei dem statistische Zusammenhänge zwischen Sensordaten, Zustandsindikatoren oder Ereignissen im Vordergrund stehen. In diesen Ansätzen werden Labels häufig aus historischen Zustandsdaten, Wartungsereignissen oder aggregierten Kennzahlen abgeleitet, ohne dass deren semantische oder ursächliche Bedeutung systematisch reflektiert wird. Das Labeling fungiert damit primär als technische Voraussetzung für überwachte Lernverfahren und nicht als integraler Bestandteil eines wissensbasierten Modellierungsansatzes. Konzeptionelle und referenzmodellnahe Arbeiten adressieren Kausalität teilweise auf einer abstrakten oder konzeptionellen Ebene, etwa durch die Forderung nach erklärbaren Modellen, die Einbindung von Domänenwissen oder die Berücksichtigung von Fehlerursachen. Diese Aspekte bleiben jedoch überwiegend auf einer Ziel- oder Anspruchsebene und werden nicht in operative Mechanismen zur Erfassung, Strukturierung oder Nutzung von Ursachenwissen überführt. Insbesondere fehlt häufig eine

klare Trennung zwischen beobachteten Symptomen, modellierten Zuständen und tatsächlichen Ursachen. Auffällig ist zudem, dass Labelingstrategien nur selten explizit beschrieben werden. Weder der Ursprung der Labels noch deren Validierung, Aktualisierung oder Kontextualisierung werden systematisch betrachtet. Die Rolle von Domänenexperten, anlagenspezifischer Dokumentation oder betrieblichen Erfahrungswerten wird zwar teilweise erwähnt, jedoch nicht als Bestandteil eines formalen, wiederverwendbaren Labeling- oder Wissensprozesses modelliert.

Zusammenfassend lässt sich feststellen, dass Kausalität und Labeling in den betrachteten Arbeiten überwiegend implizit, fragmentiert oder rein funktional behandelt werden. Eine explizite Verknüpfung zwischen datengetriebenen Modellen, ursachenbezogenem Wissen und systematischem Labeling ist nur in Ansätzen erkennbar. Damit bleibt der Kausalitäts- und Labelingbezug eine der zentralen Schwachstellen bestehender Ansätze und stellt eine wesentliche Voraussetzung für die Weiterentwicklung von rein prädiktiven hin zu erklärbaren und langfristig nutzbaren Instandhaltungsstrategien dar.

Dimension D - System- und Infrastruktureinbettung. Die Betrachtung entlang der System- und Infrastruktureinbettung veranschaulicht, dass dieser Aspekt in den herangezogenen Arbeiten zwar häufig adressiert, jedoch nur selten konsequent und durchgängig ausgearbeitet wird. Viele Beiträge erkennen die Notwendigkeit an, datengetriebene Instandhaltungsansätze in bestehende Produktions- und IT-Landschaften zu integrieren, verbleiben dabei jedoch auf einer konzeptionellen oder exemplarischen Ebene. Architekturbezogene Arbeiten thematisieren die Einbettung in industrielle Umgebungen häufig über die Anbindung an Datenquellen, Kommunikationsprotokolle oder Middleware-Komponenten. Die Integration wird dabei primär technisch verstanden, etwa als Verbindung von Sensorik, Edge-Komponenten und Cloud-Diensten. Eine explizite Verortung der Analyse- und Entscheidungslogik innerhalb bestehender betrieblicher Systeme, wie beispielsweise Instandhaltungs- oder Produktionsmanagementsysteme, erfolgt jedoch nur eingeschränkt. Konzeptionelle Frameworks und referenzmodellnahe Arbeiten adressieren die Systemeinbettung meist abstrakter, indem sie auf industrielle Referenzarchitekturen, cyber-physische Produktionssysteme oder allgemeine IT-/OT-Strukturen Bezug nehmen. Diese Einordnung dient der Kontextualisierung der Ansätze, ersetzt jedoch keine konkrete Modellierung der Schnittstellen, Datenübergaben und Verantwortlichkeiten zwischen datengetriebenen Modellen und operativen Systemen. Insbesondere bleibt häufig offen, wie Analyseergebnisse in bestehende Entscheidungs- und Ausführungsprozesse integriert werden sollen. Auffällig ist zudem, dass viele Arbeiten von idealisierten oder neu aufzubauenden Systemlandschaften ausgehen. Bestehende Produktionsinfrastrukturen, historisch gewachsene IT-Systeme und organisatorische Rahmenbedingungen werden zwar erwähnt, jedoch nicht systematisch als Randbedingungen für die Modell- und Systemgestaltung berücksichtigt. Dadurch entsteht eine Lücke zwischen theoretischer Modellierung und praktischer Umsetzbarkeit in realen Produktionsumgebungen.

Zusammenfassend zeigt sich, dass die System- und Infrastruktureinbettung in den betrachteten Arbeiten häufig als notwendige Voraussetzung anerkannt, jedoch selten als eigenständige Gestaltungsdimension ausgearbeitet wird. Die fehlende explizite Model-

lierung der Einbettung erschwert die Übertragbarkeit, Skalierbarkeit und nachhaltige Nutzung datengetriebener Instandhaltungsansätze und verdeutlicht die Bedeutung dieser Dimension als verbindendes Element zwischen analytischen Modellen und operativem Betrieb.

Dimension E - Weiterentwicklungsfähigkeit. Die Analyse der Weiterentwicklungsfähigkeit macht deutlich, dass dieser Aspekt in den betrachteten Arbeiten nur in sehr begrenztem Umfang systematisch adressiert wird. Zwar erkennen viele Beiträge an, dass datengetriebene Instandhaltungsansätze über längere Zeiträume weiterentwickelt werden müssen, konkrete Mechanismen zur strukturierten Akkumulation, Persistierung und Wiederverwendung von Wissen bleiben jedoch meist unspezifiziert. In architekturbezogenen Arbeiten beschränken sich Rückkopplungsmechanismen häufig auf die technische Ebene, etwa in Form von Modellaktualisierungen, Retraining-Zyklen oder Feedbackschleifen innerhalb einzelner Analysekomponenten. Diese Rückkopplungen dienen primär der kurzfristigen Leistungsverbesserung einzelner Modelle, nicht jedoch dem Aufbau eines übergeordneten, systematisch nutzbaren Wissensbestands. Ereignisse, Ursachen oder getroffene Maßnahmen werden selten so erfasst, dass sie über den unmittelbaren Anwendungsfall hinaus wiederverwendbar sind. Konzeptionelle Frameworks und referenzmodellnahe Arbeiten thematisieren die Notwendigkeit von Lernen und kontinuierlicher Verbesserung meist auf einer strategischen oder methodischen Ebene. Lernprozesse werden dabei als wiederkehrende Schleifen oder Reifegradentwicklungen beschrieben, ohne dass klar wird, welche Informationen konkret rückgeführt werden, in welcher Form sie gespeichert sind und wie sie in nachgelagerte Analyse- oder Entscheidungsprozesse einfließen. Der Wissensbegriff bleibt damit abstrakt und nur lose an operative Daten- und Modellartefakte gekoppelt. Auffällig ist zudem, dass nur wenige Arbeiten explizit zwischen Daten, Informationen und Wissen unterscheiden. Historische Betriebsdaten werden zwar vielfach gespeichert und für erneutes Training genutzt, eine darüber hinausgehende Strukturierung von Ursachenwissen, Kontextinformationen oder Maßnahmenhistorien findet jedoch kaum statt. Damit fehlt häufig die Grundlage für einen systematischen Übergang von reaktiven oder prädiktiven Ansätzen hin zu langfristig lernenden, adaptiven Instandhaltungsstrategien.

Zusammenfassend zeigt sich, dass die Weiterentwicklungsfähigkeit in den betrachteten Arbeiten überwiegend implizit oder fragmentiert behandelt wird. Rückkopplung wird primär als technischer Anpassungsmechanismus verstanden, nicht jedoch als integraler Bestandteil eines wissensbasierten, über Anwendungsfälle hinweg lernenden Gesamtsystems. Diese Dimension erweist sich damit als entscheidend für die nachhaltige Weiterentwicklung datengetriebener Instandhaltungsansätze und bildet eine wesentliche Voraussetzung für deren langfristige Wirksamkeit und Skalierbarkeit.

Querdimensionale Synthese der Analyseergebnisse. Die querdimensionale Betrachtung der Analyseergebnisse verdeutlicht, dass bestehende Arbeiten datengetriebene Instandhaltungsstrategien zwar entlang einzelner Dimensionen adressieren, diese jedoch nicht in einer integrierten und durchgängigen Weise zusammenführen. Über alle Dimensionen hinweg zeigt sich ein wiederkehrendes Muster struktureller Trennungen zwischen

Abstraktion und operativer Umsetzung, zwischen Datenverarbeitung und Ursachenbezug sowie zwischen Modellierung und langfristiger Wissensnutzung.

Entlang der Abstraktionsebene wird deutlich, dass insbesondere explizite Referenzmodelle und referenzmodellnahe Arbeiten einen hohen Strukturierungsanspruch verfolgen, dabei jedoch zentrale Aspekte der operativen Konkretisierung offenlassen. So fokussiert das Referenzmodell PriMa-X primär auf Prozessschritte, Reifegrade und methodische Einordnung preskriptiver Instandhaltung, während die konkrete Ausgestaltung der zugrunde liegenden Datenverarbeitung, der Datenflüsse sowie der technischen Systemintegration nicht näher spezifiziert wird [vgl. Nemeth, Ansari, Sihm et al. 2018, S.1041-1044]. Ein vergleichbares Abstraktionsniveau zeigt sich bei PMMI 4.0, das funktionale und prozessuale Strukturen für prädiktive Instandhaltung formuliert und unterschiedliche Analysephasen unterscheidet, jedoch bewusst auf eine durchgängige technische Modellierung der Datenpipeline verzichtet [vgl. Sang, L. Xu und Vrieze 2021, S.5-8]. Die Datenverarbeitung wird hier als logische Abfolge von Schritten verstanden, nicht jedoch als explizit modelliertes Bindeglied zwischen Datenquellen, Analysemodellen und operativer Nutzung. Auch das holistische Referenzarchitekturmodell von *Uhlmann et al. (2021)* verfolgt einen hohen Abstraktionsanspruch, indem es Ebenen, Funktionsblöcke und Informationsflüsse für prädiktive Instandhaltung systematisch strukturiert. Die konkrete technische Realisierung der Datenpipeline sowie deren Einbettung in bestehende IT-Systeme werden jedoch nicht im Detail ausgearbeitet, sondern explizit als anwendungsspezifisch ausgeklammert [vgl. Uhlmann et al. 2021, S.1431-1432]. Ein ähnliches Muster findet sich bei *Weller et al. (2024)*, die ein Referenzmodell für die Integration präskriptiver Ansätze formulieren. Obwohl das Modell klare funktionale Rollen und Prozessschritte definiert, bleibt die operative Konkretisierung der Datenverarbeitung, insbesondere hinsichtlich persistenter Datenspeicherung, Rückkopplung von Modellergebnissen und technischer Integration, weitgehend offen [vgl. Weller et al. 2024, S.26-29]. Damit zeigt sich über mehrere repräsentative Arbeiten hinweg ein konsistentes Muster: Mit zunehmendem Abstraktionsgrad steigt zwar die Vergleichbarkeit und Übertragbarkeit der Modelle, gleichzeitig nimmt jedoch die operative Konkretisierung der Datenverarbeitung und Systemintegration ab. Die Brücke zwischen abstrahierter Modellstruktur und implementierbarer Datenpipeline bleibt in expliziten Referenzmodellen und referenzmodellnahen Arbeiten systematisch ungeschlossen.

Die querdimensionale Betrachtung der expliziten Datenpipeline zeigt, dass Datenverarbeitung in den betrachteten Arbeiten zwar nahezu durchgängig als zentraler Bestandteil datengetriebener Instandhaltung verstanden wird, die Pipeline selbst jedoch nur selten als eigenständiges, abstrahiertes Modellelement ausgearbeitet ist. Stattdessen oszillieren die Beiträge zwischen technisch-konkreten Implementierungen und rein prozessual-logischen Beschreibungen der Datenverarbeitung. Mehrere architekturbezogene Arbeiten modellieren Datenpipelines explizit auf technischer Ebene. *Kammerer et al. (2020)* beschreiben eine konkrete Sensor Processing Pipeline (SSP), die industrielle Sensordaten über Kommunikationsprotokolle, Streaming-Komponenten und Verarbeitungsschritte bis zur Analyse führt. Diese Pipeline ist klar implementierungsnah ausgearbeitet, bleibt jedoch stark an konkrete technische Annahmen und Systemarchitekturen gebunden und wird nicht als übertragbare Referenzstruktur abstrahiert. Ein ähnlicher Fokus zeigt sich bei *Bellavista et*

al. (2019), die detaillierte Gestaltungsrichtlinien für Big-Data-Pipelines in Industrie-4.0-Umgebungen formulieren, einschließlich Datenerfassung, -übertragung, -speicherung sowie -analyse. Auch hier fungiert die Pipeline primär als technische Realisierung und nicht als abstrahiertes Modellelement. Demgegenüber beschreiben mehrere konzeptionelle und referenzmodellnahe Arbeiten Datenverarbeitung lediglich als logische Abfolge funktionaler Schritte. *Sang et al. (2021)* stellen ein umfangreiches Datenmodell für Predictive Maintenance vor, das verschiedene Datenkategorien wie Maschinen-, Defekt- und Wartungsdaten integriert. Die Datenpipeline selbst bleibt jedoch implizit und wird als logische Struktur vorausgesetzt, ohne operative Flüsse, Persistenz- oder Rückkopplungspunkte explizit zu modellieren [vgl. Sang, L. Xu und Vrieze 2021, S.6-8]. Ein vergleichbares Muster zeigt sich bei *Paolanti et al. (2018)*, wo der Weg von Sensordaten über Vorverarbeitung hin zur Analyse beschrieben wird, jedoch ohne eine durchgängige, modellhafte Spezifikation der Pipeline als wiederverwendbare Struktur. Auch explizite Referenzmodelle adressieren die Datenpipeline überwiegend indirekt. *Nemeth et al. (2018)* ordnen mit PriMa-X die Datenverarbeitung als Bestandteil des Analyse- und Entscheidungsprozesses ein, ohne die Pipeline selbst als zentrales Bindeglied zwischen Datenerhebung, Modelltraining, Anwendung und Rückkopplung formal auszugestalten. *Ansari et al. (2018)* stellen mit PriMa eine konkrete Architektur für präskriptive Instandhaltung vor und validieren diese anhand eines Anwendungsszenarios. Eine Abstraktion der Datenpipeline zu einem übertragbaren, vergleichbaren Referenzmodellelement erfolgt nicht. Darüber hinaus bleiben Datenflüsse und Rückkopplungen implizit in der Architektur verankert und werden nicht als eigenständige Data-Pipeline-Struktur modelliert. Neuere Arbeiten, etwa *Ordieres-Meré et al. (2025)*, adressieren datengetriebene Überwachungssysteme für und präskriptive Ansätze mit expliziten Datenverarbeitungsschritten, jedoch ebenfalls primär aus einer anwendungs- und systembezogenen Perspektive. Die Datenpipeline wird hier als Teil eines konkreten Systems verstanden, nicht jedoch als abstrahierte, übertragbare Struktur, die unterschiedliche Instandhaltungsstrategien konsistent verbinden könnte. Zusammenfassend zeigt sich entlang dieser Dimension ein konsistentes Muster. Datenpipelines sind entweder technisch detailliert, aber stark kontextgebunden, oder abstrakt beschrieben, aber operativ unvollständig. Eine explizite Datenpipeline, die sowohl abstrahiert als auch operativ anschlussfähig ist und damit als verbindendes Element zwischen Referenzmodell, Systemeinkbettung, Kausalitätsbezug und Wissensrückkopplung fungiert, ist in den betrachteten Arbeiten bislang nicht systematisch ausgearbeitet.

Die Analyse der Dimension Kausalität und Labeling zeigt, dass zahlreiche Arbeiten zwar kausal motivierte Zielsetzungen formulieren oder ursachennahe Informationen nutzen, diese jedoch nur selten in einen expliziten, formalisierten und wiederverwendbaren Kausal- und Labelingprozess überführen. Der Ursachenbezug bleibt damit häufig implizit in Datenstrukturen, Architekturen oder Use-Case-spezifischen Annahmen verankert, ohne als eigenständiges Modellelement abstrahiert zu werden. Mehrere Arbeiten integrieren ursachennahe Informationen in Form von Fehlerkategorien, Wartungsereignissen oder Zustandsklassen. So enthält das Datenmodell von *Sang et al. (2021)* explizite Defekt-Daten, die prinzipiell einen Ursachenbezug ermöglichen. Diese Informationen werden jedoch primär als Datenattribute innerhalb eines Datenmodells geführt, wobei eine methodische

Trennung zwischen Symptomen, Zuständen und Ursachen sowie deren systematische Nutzung für kausales Labeling oder Modellinterpretation nicht explizit ausgearbeitet wird [vgl. ebd., S.6-9]. Auch *Németh et al. (2018)* adressieren mit PriMa-X die Bedeutung geeigneter, gelabelter Daten für präskriptive Instandhaltung und heben die Rolle von Expertenwissen im Entscheidungsprozess hervor. Der konkrete Prozess, wie Ursachenwissen aus Domänenexpertise, Dokumentation oder Betriebserfahrung strukturiert erfasst, validiert, persistiert und für das Training oder die Weiterentwicklung datengetriebener Modelle genutzt wird, bleibt jedoch offen. Labeling fungiert damit eher als implizite Voraussetzung denn als explizit modellierter Wissensprozess [vgl. *Nemeth, Ansari, Sihn et al. 2018*, S.1041-1043]. In der von *Ansari et al. (2019)* vorgestellten Architektur fließen ursachenbezogene Informationen in Entscheidungs- und Optimierungslogiken ein. Die Zuordnung von Ursachen zu erfolgt jedoch architekturenspezifisch. Eine Abstraktion der Zuordnung von Ursachen zu Daten, Modellen und Entscheidungen zu einem übertragbaren, referenzmodellhaften Kausal- und Labelingmechanismus wird nicht vorgenommen. Ein ähnliches Muster zeigt sich bei *Paolanti et al. (2018)*, die gelabelte Daten für die Modellbildung im Rahmen prädiktiver Instandhaltung nutzen, ohne den Ursprung, die Validierung oder die semantische Bedeutung der Labels näher zu spezifizieren. Labels werden hier als gegebene Trainingsgrundlage verstanden, nicht jedoch als Ergebnis eines systematischen, wissensbasierten Prozesses. In neueren Arbeiten mit stärkerem Fokus auf digitale Zwillinge und hybride Architekturen wird Kausalität teilweise auf konzeptioneller Ebene adressiert. So betonen *dos Santos et al. (2024)* die Bedeutung von Ursachenverständnis und Modelltransparenz im Kontext hybrider Architekturen für Digitale Zwillinge, verbleiben jedoch bei einer abstrakten Diskussion kausaler Zusammenhänge, ohne einen operativen Mechanismus zur kausalen Annotation und Nutzung von Trainingsdaten zu spezifizieren. Ein vergleichbares Muster zeigt sich bei *Kohl et al. (2021)*, die eine modulare Architektur für föderiertes Lernen in der industriellen Instandhaltung vorstellen und Knowledge Graphs zur semantischen Repräsentation von Domänen- und Kontextwissen einsetzen. Die Knowledge Graphs dienen dabei primär der Kontextualisierung und Integration heterogener Informationsquellen sowie der Unterstützung KI-basierter Assistenzfunktionen [vgl. *L. Kohl et al. 2021*, S.221]. Eine explizite Modellierung eines durchgängigen, kausalen Labelingprozesses, der Ursachenwissen systematisch aus Betriebsereignissen ableitet, für das Training datengetriebener Modelle nutzt und die Ergebnisse persistiert rückkoppelt, wird jedoch nicht ausgearbeitet. In der Gesamtschau wird deutlich, dass der Umgang mit Ursachenwissen in den betrachteten Arbeiten überwiegend fragmentarisch bleibt. Zwar sind in vielen Beiträgen ursachennahe Informationen, Kontextdaten oder Experteneinschätzungen vorhanden, diese werden jedoch selten zu einem expliziten, nachvollziehbaren Kausalzusammenhang verdichtet. Stattdessen fungieren Ursachenbezüge häufig als implizite Annahmen innerhalb von Datenstrukturen, Modellarchitekturen oder anwendungsspezifischen Entscheidungsregeln. Labeling wird in diesem Kontext primär als technische Voraussetzung für den Einsatz überwachter Lernverfahren verstanden, nicht jedoch als eigenständiger, wissensbasierter Prozess. Die Herkunft, Semantik und Validierung von Labels bleiben oftmals unklar und sind eng an spezifische Fallstudien oder Architekturen gebunden. Eine systematische Trennung zwischen Symptomen, Zuständen und zugrunde liegenden Ursachen ist nur selten explizit ausgearbeitet.

Folglich stellt ein übergreifender Mechanismus, der Ursachenwissen strukturiert erfasst, konsistent mit Daten und Modellen verknüpft und über Anwendungsfälle hinweg nutzbar macht, einen Bedarf in datengetriebenen Instandhaltungsstrategien dar. Kausalität wird zwar als Zielgröße adressiert, jedoch nicht als durchgängiges Gestaltungselement in der Modellierung datengetriebener Instandhaltungsansätze etabliert.

Die Betrachtung der System- und Infrastruktureinbettung zeigt, dass bestehende Arbeiten datengetriebene Instandhaltungsansätze zwar häufig in einen industriellen Kontext einordnen, diese Einbettung jedoch selten als eigenständige Gestaltungsdimension ausarbeiten. Vielmehr wird die bestehende Produktions- und IT-Landschaft meist als gegebener Rahmen vorausgesetzt, innerhalb dessen datengetriebene Modelle operieren, ohne dass deren Rolle, Schnittstellen und Verantwortlichkeiten systematisch modelliert werden. Mehrere Arbeiten adressieren die Einbettung datengetriebener Instandhaltungsansätze primär aus einer technischen Perspektive. Architekturbezogene Beiträge fokussieren dabei häufig auf Kommunikationsprotokolle, Middleware oder Datenanbindungen zwischen Sensorik, Analysekomponenten und IT-Systemen. So beschreiben *Kammerer et al. (2020)* die Integration industrieller Sensordaten über spezifische Kommunikations- und Verarbeitungsketten detailliert. Ein vergleichbarer Fokus auf technische Integration zeigt sich auch bei *Bellavista et al. (2019)*, die industrielle Datenpipelines entlang konkreter Systemkomponenten und Integrationsmechanismen ausarbeiten, sowie bei *Parapalli und Shetty (2025)*, die eine hybride Edge-Cloud-Architektur für produktionsnahe Monitoring- und Maintenance-Anwendungen vorstellen. Allen diesen Ansätzen ist gemeinsam, dass sie eine funktionierende technische Einbettung ermöglichen, die Systemintegration jedoch stark an konkrete Architekturen und Anwendungsfälle gebunden bleibt und nicht zu einem übertragbaren, referenzmodellhaften Einbettungskonzept abstrahiert wird. Konzeptionelle und referenzmodellnahe Arbeiten verorten datengetriebene Instandhaltungsansätze demgegenüber auf einer höheren Ebene, indem sie auf cyber-physische Produktionssysteme, Industrie-4.0-Referenzarchitekturen oder generische IT-/OT-Strukturen Bezug nehmen. In der Arbeit von *Sang et al. (2021)* werden Wartungsprozesse, Ressourcenabhängigkeiten und Datenquellen in einen übergeordneten Produktionskontext eingeordnet. Ähnliche Kontextualisierungen finden sich in der Arbeit von *Uhlmann et al. (2021)*, die ein holistisches Referenzarchitekturmodell für Predictive Maintenance formulieren, sowie in der Ausarbeitung von *Weller et al. (2024)*, die die Integration präskriptiver Ansätze auf einer funktional-strukturellen Ebene beschreiben. Trotz des höheren Abstraktionsgrads bleibt in diesen Arbeiten die konkrete operative Verortung von Analyseergebnissen innerhalb bestehender Instandhaltungs-, Produktions- oder Entscheidungsprozesse weitgehend offen. Ein ähnliches Muster zeigt sich bei Arbeiten mit explizitem Fokus auf Wissensintegration. *Zenkert et al. (2021)* thematisieren die Einbindung von Erfahrungswissen, Dokumentationen und semantischen Informationsstrukturen in Smart-Factory-Umgebungen. Die infrastrukturelle Einbettung erfolgt hierbei vor allem auf Ebene von Informations- und Wissenssystemen, ohne die Kopplung an operative Instandhaltungsprozesse oder datengetriebene Entscheidungsmechanismen systematisch zu modellieren. Auffällig ist zudem, dass viele Arbeiten implizit von neu aufzubauenden oder idealisierten Systemlandschaften ausgehen. Historisch gewachsene Produktionsinfrastrukturen, heterogene IT-Systeme und organisatorische Randbedingungen werden zwar

erwähnt, jedoch selten als zentrale Entwurfsrestriktionen berücksichtigt. Dadurch entsteht eine Diskrepanz zwischen der konzeptionellen Modellierung datengetriebener Ansätze und deren nachhaltiger Integration in reale industrielle Umgebungen. Zusammenfassend lässt sich festhalten, dass die System- und Infrastruktureinbettung in den betrachteten Arbeiten überwiegend entweder technisch-pragmatisch oder kontextuell-abstrakt behandelt wird. Eine explizite, referenzmodellhafte Verortung datengetriebener Instandhaltungsansätze innerhalb bestehender Produktions- und IT-Strukturen, die sowohl operative Prozesse als auch Rückkopplungsmechanismen berücksichtigt, ist bislang nicht systematisch ausgearbeitet.

Die Analyse der Weiterentwicklungs- und Evolutionsfähigkeit zeigt, dass bestehende Arbeiten datengetriebene Instandhaltung zwar häufig als lernenden Ansatz verstehen, die Weiterentwicklung jedoch überwiegend auf die Anpassung einzelner Modelle oder Parameter beschränken. Eine systematische Evolutionsfähigkeit des Gesamtsystems wird nur selten explizit adressiert. Mehrere Arbeiten begreifen Weiterentwicklung primär als kontinuierliche Modellpflege. So betonen *Lee et al. (2020)* die Nutzung historischer Betriebs- und Zustandsdaten zur Verbesserung analytischer Modelle und zur Unterstützung verschiedener Instandhaltungsfunktionen. Die Weiterentwicklung erfolgt hierbei modellzentriert, wobei eine darüber hinausgehende Anpassung der zugrunde liegenden Daten- oder Entscheidungslogik nicht systematisch betrachtet wird. Ein ähnliches Verständnis zeigt sich bei *Ordieres-Meré et al. (2025)*, die iterative Analyse- und Optimierungsschritte innerhalb eines konkreten Anwendungssystems beschreiben, ohne diese Weiterentwicklung zu einem übertragbaren Evolutionskonzept zu abstrahieren. Andere Arbeiten erweitern die Perspektive, verbleiben jedoch auf einer konzeptionellen Ebene. *Zenkert et al. (2021)* adressieren die Integration von Erfahrungswissen und Dokumentationen, um Entscheidungsunterstützung in Smart-Factory-Umgebungen zu verbessern. Diese Ansätze unterstützen die Kontextualisierung und Interpretation von Informationen, sind jedoch nicht explizit als Mechanismus zur systematischen Weiterentwicklung datengetriebener Instandhaltungsmodelle ausgestaltet. Auch explizite Referenzmodelle und referenzmodellnahe Arbeiten thematisieren Evolution meist abstrakt. PriMa-X von *Nemeth et al. (2018)* beschreibt Feedback- und Verbesserungszyklen als Bestandteil präskriptiver Instandhaltung, konkretisiert jedoch nicht, wie Erkenntnisse aus dem laufenden Betrieb strukturiert genutzt werden, um Modelle, Labelingstrategien oder Entscheidungsregeln über mehrere Zyklen hinweg weiterzuentwickeln. Vergleichbar adressiert PriMa von *Ansari et al. (2019)* die Anpassung und Rückkopplung innerhalb einer validierten Architektur, ohne diese Weiterentwicklung zu einem abstrahierten, übertragbaren Evolutionsmechanismus zu erheben. Neuere Arbeiten mit Fokus auf digitale Zwillinge oder hybride Architekturen erkennen zwar die Notwendigkeit langfristiger Anpassungsfähigkeit an. So diskutieren *dos Santos et al. (2024)* Lern- und Anpassungsprozesse im Kontext hybrider Architekturen für Digitale Zwillinge, verbleiben jedoch bei einer allgemeinen Betrachtung von Modellaktualisierung und Systemanpassung. Eine explizite Modellierung der Weiterentwicklung als durchgängiger, systematischer Prozess, der Betriebserfahrungen in zukünftige Modell- und Entscheidungsstrukturen überführt, wird nicht ausgearbeitet. Zusammenfassend zeigt sich, dass Weiterentwicklung in den betrachteten Arbeiten überwiegend als lokale

Optimierung einzelner Komponenten verstanden wird. Eine explizite, referenzmodellhafte Konzeption, die die langfristige Evolution datengetriebener Instandhaltungsansätze über Daten, Modelle, Labeling und Entscheidungslogiken hinweg systematisch unterstützt, ist bislang nicht erkennbar.

Die Analyse der bestehenden Arbeiten zeigt, dass datengetriebene Instandhaltungsansätze bislang überwiegend fragmentiert adressiert werden. Zwar existieren architekturbezogene Lösungen, konzeptionelle Frameworks sowie referenzmodellnahe und explizite Referenzmodelle, diese verbinden jedoch die betrachteten zentralen Dimensionen nicht in integrierter und durchgängiger Weise. Insbesondere fehlt ein Ansatz, der datengetriebene Modelle systematisch in bestehende Produktionsinfrastrukturen einbettet und dabei die Entwicklung, Nutzung und Weiterentwicklung kausal interpretierbarer Modelle entlang einer expliziten Datenpipeline strukturiert unterstützt. Darüber hinaus wird deutlich, dass Kausalität und Labeling in bestehenden Arbeiten meist implizit oder Fallsudien-spezifisch behandelt werden und selten als eigenständige, wiederverwendbare Gestaltungsdimension modelliert sind. Ebenso bleibt die langfristige Weiterentwicklung datengetriebener Instandhaltungsansätze häufig auf die lokale Optimierung einzelner Modelle beschränkt, ohne einen systematischen Evolutionsmechanismus für Daten, Modelle und Entscheidungslogiken bereitzustellen.

Daraus ergibt sich ein klarer Forschungsbedarf nach einem integrierten Referenzmodell für datengetriebene Instandhaltungsstrategien, das in bestehende Produktions- und IT-Infrastrukturen eingebettet ist, eine explizite und durchgängige Datenpipeline als verbindendes Strukturierungselement definiert, kausalen Ursachenbezug sowie systematisches Labeling als zentrale Modellierungsprinzipien verankert und die Weiterentwicklung datengetriebener Modelle und Entscheidungsmechanismen über den gesamten Lebenszyklus hinweg unterstützt. Dieser identifizierte Forschungsbedarf bildet die Grundlage für die Ableitung der Forschungsfragen im folgenden Kapitel.

4.2 Herleitung der Forschungsfragen

Forschungsfragen dienen nach *Gläser und Laudel (2010)* dem systematischen Ausbau des wissenschaftlichen Wissensstandes, indem sie an einen spezifischen Stand der Forschung zu einem bestimmten Zeitpunkt anknüpfen und gezielt identifizierte Wissenslücken adressieren. Sie setzen eine reflektierte Auseinandersetzung mit bestehenden theoretischen Ansätzen, empirischen Befunden und konzeptionellen Arbeiten voraus und zielen darauf ab, bislang unzureichend betrachtete Zusammenhänge, Konzepte oder Gestaltungsansätze explizit zu untersuchen [vgl. Gläser und Laudel 2010, S.65ff.].

Die Ableitung der Forschungsfragen erfolgt im Rahmen der Forschungsagenda und entspricht damit dem abschließenden Schritt (**V**) der systematischen Literaturanalyse (vgl. **Kapitel 2.5.1**). Sie basiert auf der systematischen Aufarbeitung der theoretischen Grundlagen in **Kapitel 3**, der in **Kapitel 4.1** dargestellten Literaturanalyse sowie der querdimensionalen Betrachtung und Abgrenzung bestehender Arbeiten in **Kapitel 4.1.5**. In dieser Synthese werden die identifizierten Erkenntnisse verdichtet und in konkrete, forschungsleitende Fragestellungen überführt. Ergänzend fließen domänenspezifische Erkennt-

nisse aus dem industriellen Anwendungskontext in die Ableitung der Forschungsfragen ein. Diese ergeben sich aus der beruflichen Tätigkeit des Forschenden im Produktionsumfeld eines Automobilherstellers und dienen der praxisnahen Einordnung der identifizierten Forschungslücken. Die Forschungsfragen verbinden damit den bestehenden wissenschaftlichen Erkenntnisstand mit realen industriellen Herausforderungen und bilden die Grundlage für die weitere gestaltungsorientierte Ausrichtung der Arbeit.

Die Analyse des Forschungsstandes zeigt, dass datengetriebene Instandhaltungsstrategien bislang nicht als integrierte Gesamtsysteme betrachtet werden. Zwar existieren architekturbezogene Ansätze, konzeptionelle Frameworks sowie referenzmodellnahe und explizite Referenzmodelle, diese adressieren jedoch entlang der in **Kapitel 4.1.5** definierten zentralen Dimensionen jeweils isoliert. Ein Referenzmodell, das diese Dimensionen konsistent zusammenführt und datengetriebene Instandhaltungsansätze als Bestandteil realer Produktionsumgebungen entlang einer expliziten, kausal orientierten Data Pipeline strukturiert unterstützt, fehlt bislang. Aus diesem Forschungsbedarf ergibt sich die forschungsleitende Fragestellung der Arbeit:

Leitforschungsfrage:

Wie ist ein Referenzmodell einer intelligenten Data Pipeline für Produktionsumgebungen zu gestaltet, das sich in bestehende IT-Infrastrukturen integrieren lässt und einen kausal-prädiktiven Instandhaltungsansatz als Grundlage für eine präskriptive Instandhaltungsstrategie strukturiert unterstützt?

Zur Beantwortung der Leitforschungsfrage ist neben der Analyse bestehender wissenschaftlicher Ansätze insbesondere die praktische Erprobung in einer realen Produktionsumgebung erforderlich. Durch die Integration des Referenzmodells in die bestehende IT-Infrastruktur des Presswerks eines Automobilunternehmens können sowohl die Umsetzbarkeit als auch integrationsbedingte Herausforderungen systematisch untersucht werden. Daraus ergibt sich die erste Forschungsfrage:

Forschungsfrage 1:

Welche Herausforderungen ergeben sich bei der Integration eines Referenzmodells einer intelligenten Data Pipeline für datengetriebene Instandhaltungsstrategien in die bestehende IT-Infrastruktur einer Produktionsumgebung?

Auf Basis des integrierten Referenzmodells bildet die Entwicklung, das Training und der Einsatz von Machine- und Deep-Learning-Modellen einen zentralen Bestandteil datengetriebener Instandhaltungsansätze. Die Nutzung von Produktions- und Maschinendaten zur Informationsgewinnung erfordert dabei den gezielten Einsatz geeigneter Data-Mining-Methoden, die im Rahmen mehrerer Fallstudien untersucht werden. Daraus folgt die zweite Forschungsfrage:

Forschungsfrage 2:

Welche Herausforderungen bestehen bei der Anwendung von Data-Mining-Methoden auf Produktions- und Maschinendaten im Hinblick auf die Gewinnung nutzbarer Informationen für datengetriebene Instandhaltungsstrategien?

Die Analyse des Forschungsstandes zeigt zudem, dass der systematische Einbezug von Domänenwissen, wie beispielsweise aus dem Erfahrungsschatz von Instandhaltungsmitarbeitern oder aus technischen Anlagendokumentationen, bislang nur unzureichend formalisiert ist. Insbesondere der manuelle Aufwand für die Nutzung dieses Wissens stellt eine wesentliche Einschränkung dar. Daraus ergibt sich der Bedarf nach Konzepten zur automatisierten Verknüpfung von Wissen und Sensordaten, was zur dritten Forschungsfrage führt:

Forschungsfrage 3:

Welche Anforderungen lassen sich an Konzepte ableiten, die Wissen aus technischen Anlagendokumentationen automatisiert mit Sensordaten verknüpfen, um kausal begründete Handlungsempfehlungen abzuleiten?

Die bisherigen Forschungsfragen fokussieren jeweils spezifische Gestaltungs- und Anwendungsaspekte des Referenzmodells einer intelligenten Data Pipeline. Während die ersten drei Forschungsfragen die Integration in bestehende IT-Infrastrukturen, die Anwendung datengetriebener Methoden sowie die systematische Nutzung von Domänenwissen adressieren, ergibt sich daraus die Notwendigkeit einer übergreifenden Betrachtung. Insbesondere stellt sich die Frage, wie die gewonnenen Erkenntnisse und entwickelten Ansätze über den kausal-prädiktiven Instandhaltungsansatz hinaus einzuordnen sind und welchen Beitrag sie zur Vorbereitung präskriptiver Instandhaltungsstrategien leisten können. Vor diesem Hintergrund adressiert die vierte Forschungsfrage keine weitere isolierte Gestaltungsdimension, sondern verfolgt eine synthetisierende Perspektive, in der die Ergebnisse der vorangegangenen Forschungsfragen zusammengeführt und im Hinblick auf ihre Anschlussfähigkeit an präskriptive Instandhaltungsstrategien reflektiert werden. Die vierte Forschungsfrage dient damit der zusammenfassenden Einordnung der Arbeitsergebnisse und bildet die konzeptionelle Brücke zwischen der entwickelten intelligenten Data Pipeline und weiterführenden präskriptiven Instandhaltungsansätzen.

Forschungsfrage 4:

Wie kann ein kausal-prädiktiver Instandhaltungsansatz, der durch eine intelligente Data Pipeline unterstützt wird, als Grundlage für präskriptive Instandhaltungsstrategien genutzt werden?

Zur weiteren Strukturierung der Arbeit und zur Sicherstellung der Nachvollziehbarkeit wird im Folgenden dargestellt, in welchen Kapiteln die einzelnen Forschungsfragen adressiert werden (s. **Tabelle 6**). Die Übersicht verdeutlicht die inhaltliche Verzahnung zwischen theoretischen, methodischen und empirischen Untersuchungsteilen und bildet die Grundlage für die abschließende Diskussion der Ergebnisse.

Tabelle 6: Zuordnung der Forschungsfragen zu den Kapiteln der Dissertation

Forschungsfrage	Bearbeitung in Kapitel
Leitforschungsfrage	Kapitel 5 und 6
Forschungsfrage 1	Kapitel 6.3
Forschungsfrage 2	Kapitel 6.4
Forschungsfrage 3	Kapitel 5 und 6
Forschungsfrage 4	Kapitel 5, 6 und 7

5 Entwicklung eines Referenzmodells

Ein Referenzmodell stellt in der wissenschaftlichen Diskussion ein abstraktes, technologieunabhängiges Modell dar, das als konzeptueller Bezugsrahmen für die Beschreibung, Vergleichbarkeit und Ableitung spezifischer Modelle dient [vgl. Cherdantseva et al. 2016, S.45–46; Frank 2006, S.1–2]. Es zeichnet sich durch die klare Definition von Entitäten und deren Beziehungen innerhalb einer bestimmten Problem- oder Wissensdomäne aus und soll eine einheitliche Kommunikation sowie die Wiederverwendung von modelliertem Wissen ermöglichen [vgl. Fettke und Loos 2003, S.35–37]. Ableitend aus den Arbeiten von *Fettke und Loos (2004)*, *Frank (2006)*, *Cherdantseva et al. (2016)*, *Matook und Indulska (2009)* sowie *Esswein et al. (2004)* ergeben sich die in der **Tabelle 7** aufgeführten Merkmale für ein Referenzmodell, die entsprechend als Leitbild für die Entwicklung des Referenzmodells der intelligenten Data Pipeline dienen.

Tabelle 7: Merkmale eines Referenzmodells

Abstraktheit	Modell ist technologieunabhängig, generalisiert und nicht auf einen konkreten Anwendungsfall beschränkt.
Semantische Eindeutigkeit	Entitäten und Beziehungen sind eindeutig definiert und nachvollziehbar dokumentiert.
Domänenspezifität	Referenzmodell bezieht sich auf einen spezifischen Problem- oder Anwendungsbereich.
Adaptierbarkeit	Referenzmodell dient als Vorlage und lässt sich auf konkrete Fälle anpassen.
Vergleichbarkeit	Erlaubt die Gegenüberstellung unterschiedlicher Referenzmodelle oder Ist-Zustände.
Empfehlungscharakter	Dient als normatives Leitbild.
Nachvollziehbarkeit	Herkunft, Struktur und Einsatzmöglichkeiten sind formal dokumentiert.

Vor dem Hintergrund der in **Kapitel 4** durchgeführten systematischen Analyse des Stands der Forschung wird deutlich, dass bestehende Arbeiten datengetriebene Instandhaltungsstrategien bislang überwiegend fragmentiert adressieren. Insbesondere fehlt ein integrierter Ansatz, der eine explizite und durchgängige Datenpipeline als zentrales Strukturierungselement mit einem systematischen Kausalitäts- und Wissensbezug sowie mit Mechanismen zur langfristigen Weiterentwicklung datengetriebener Modelle verbindet. Vor diesem Hintergrund verfolgt das im Rahmen dieser Arbeit entwickelte Referenzmodell das Ziel, eine abstrahierte, vergleichbare und technologieunabhängige Soll-Struktur für intelligente Data Pipelines in Produktionsumgebungen zu formulieren. Das Referenzmodell adressiert dabei bewusst nicht nur die funktionale Abfolge datengetriebener Verarbeitungsschritte, sondern integriert kausale Zusammenhänge, wissensbasierte Ableitungsmechanismen sowie Rückkopplungs- und Evolutionsaspekte als zentrale Gestaltungsprinzipien. Auf diese Weise dient das Referenzmodell als konzeptionelle Grundlage für die strukturierte Umsetzung kausal-prädiktiver Instandhaltungsansätze und bereitet deren Weiterentwicklung hin zu präskriptiven Instandhaltungsstrategien vor.

Im Folgenden wird in **Kapitel 5.1** eine Gesamtübersicht des Referenzmodells vorgestellt, die aus der iterativen, gestaltungsorientierten Vorgehensweise der Design Science

Research resultiert (vgl. **Kapitel 3** bis **6**). Die einzelnen Referenzmodell-Ebenen und ihre jeweiligen Elemente werden in den **Kapiteln 5.2** bis **5.6** detailliert beschrieben und im Hinblick auf ihre Rolle innerhalb der durchgängigen Data Pipeline, ihren Beitrag zum Kausalitäts- und Wissensbezug sowie ihre Bedeutung für die Weiterentwicklungsfähigkeit datengetriebener Instandhaltungsansätze eingeordnet. Abschließend erfolgt in **Kapitel 5.9** ein zusammenfassendes Zwischenfazit.

5.1 Gesamtübersicht des Referenzmodells

In der **Abbildung 12** ist das Referenzmodell der intelligenten Data Pipeline dargestellt, das die strukturierte Umsetzung kausal-prädiktiver Instandhaltungsansätze als Grundlage für präskriptive Instandhaltungsstrategien in der Produktion unterstützt. Das Referenzmodell ist als integriertes Gesamtsystem konzipiert und folgt dem Prinzip einer expliziten, durchgängigen Data Pipeline, die den Weg von der Datenerhebung über Analyse und Wissensnutzung bis hin zur Rückkopplung systematisch abbildet.

Zur Sicherstellung der in **Tabelle 7** aufgeführten Merkmale ist das Referenzmodell in funktionale Referenzmodell-Ebenen (RME) gegliedert. Die Struktur der intelligenten Data Pipeline umfasst die Referenzmodell-Ebenen **Datenakquise**, **Vorverarbeitung** und **Bereitstellung**, **Informationsintegration**, **Analyse**, **Überwachung**, **Entscheidungsunterstützung** sowie **Modellierung**. Diese Referenzmodell-Ebenen orientieren sich an etablierten Arbeiten aus dem Bereich datengetriebener Instandhaltung und industrieller Datenpipelines. Die zugrunde liegenden Ansätze wurden im Rahmen der systematischen Abgrenzung in **4.1.5** entlang definierter Analyse-Dimensionen untersucht und in **Tabelle 5** zusammengefasst. Auf dieser Grundlage werden die identifizierten Strukturprinzipien zu einer integrierten, referenzmodellhaften Gesamtstruktur zusammengeführt.

Die **RME 1 - Datenakquise** bildet den Einstieg in die Data Pipeline und umfasst die Erhebung instandhaltungsrelevanter Daten aus Produktionsanlagen sowie die Erfassung domänenspezifischen Wissens. Dabei werden sowohl strukturierte Maschinendaten, etwa Sensordaten und Anlagenparameter, als auch unstrukturierte Informationen aus Anlagendokumentationen und Erfahrungswissen berücksichtigt. Ziel dieser Ebene ist es, eine möglichst vollständige und kontextreiche Datenbasis für nachgelagerte Verarbeitungsschritte bereitzustellen.

Die **RME 2 - Vorverarbeitung und Bereitstellung** adressiert die Aufbereitung der erhobenen Daten im Hinblick auf Qualität, Konsistenz und Analysefähigkeit. Hierzu zählen insbesondere Maßnahmen zur Strukturierung, Harmonisierung und zeitlichen Synchronisation unterschiedlicher Datentypen. Die Vorverarbeitung erfolgt unter Berücksichtigung domänenspezifischer Anforderungen und bildet die Grundlage für eine valide Informationsintegration und Analyse.

In der **RME 3 - Informationsintegration** werden die vorverarbeiteten Daten zusammengeführt, persistent gespeichert und für Analyse- und Modellierungszwecke bereitgestellt. Diese Ebene übernimmt damit eine zentrale Rolle innerhalb der Data Pipeline, da sie sowohl die Integration heterogener Datenquellen als auch die Kontext-




Abbildung 12: Referenzmodell der intelligenten Data Pipeline

tualisierung und Anreicherung der Daten unterstützt. Ergänzend werden in dieser Ebene Labeling-Informationen und Zustandszuweisungen verortet, die für die Entwicklung und Weiterentwicklung datengetriebener Modelle erforderlich sind. Eine enge Kopplung zur Wissensdatenbank ermöglicht dabei die Nutzung bestehenden Wissens zur Unterstützung des Labeling-Prozesses sowie die kontinuierliche Anreicherung des Wissensbestands durch neue Daten und Erkenntnisse.

Die **RME 4 - Analyse** umfasst die Anwendung datengetriebener Methoden zur Zustandsbewertung und Mustererkennung. In dieser Ebene werden trainierte Analysemodelle auf kontinuierlich anfallende Produktionsdaten angewendet, um Aussagen über den aktuellen oder zukünftigen Zustand von Anlagenkomponenten abzuleiten. Die Analyseergebnisse bilden die Grundlage für die nachgelagerte Überwachung und Entscheidungsunterstützung.

Die **RME 5 - Überwachung** dient der Aufbereitung, Visualisierung und Kommunikation der Analyseergebnisse. Sie ermöglicht eine adressatengerechte Darstellung von Zuständen, Prognosen und Warnhinweisen sowie die Ableitung erster Handlungshinweise. Die Überwachung fungiert damit als Schnittstelle zwischen datengetriebenen Analysen und operativen Instandhaltungsprozessen.

Die **RME 6 - Entscheidungsunterstützung** ist als zentrales Element für die Rückkopplung und Weiterentwicklung des Gesamtsystems konzipiert, ohne dabei eine hierarchische Sonderstellung gegenüber anderen Referenzmodell-Ebenen einzunehmen. In ihr werden historische Ereignisse, Zustandsinformationen, Ursachenwissen sowie durchgeführte Instandhaltungsmaßnahmen strukturiert abgelegt und miteinander verknüpft. Die Wissensdatenbank unterstützt die systematische Nutzung von Erfahrungswissen, dient als Grundlage für kausal begründete Handlungsempfehlungen und ermöglicht die Rückführung von Modell- und Betriebsergebnissen in vorgelagerte Ebenen der Data Pipeline.

Die **RME 7 - Modellierung** adressiert die Entwicklung, das Training und die Weiterentwicklung datengetriebener Modelle. Sie stellt sicher, dass neue Erkenntnisse, aktualisierte Datenbestände und erweitertes Wissen systematisch in den Modelllebenszyklus integriert werden und trägt damit wesentlich zur langfristigen Weiterentwicklungsfähigkeit des Gesamtsystems bei.

Das vorgestellte Referenzmodell beschreibt somit eine integrierte intelligente Data Pipeline, die Daten, Informationen und Wissen über mehrere Referenzmodell-Ebenen hinweg verknüpft und durch Rückkopplungsmechanismen kontinuierlich weiterentwickelt. In den folgenden Kapiteln werden die einzelnen Referenzmodell-Ebenen detailliert beschrieben und hinsichtlich ihrer Aufgaben, Modellelemente und Schnittstellen konkretisiert.

5.2 RME 1 - Datenakquise

Die im Rahmen der intelligenten Data Pipeline verarbeiteten Informationen bilden die inhaltliche Grundlage sämtlicher nachgelagerter Verarbeitungsschritte. Entsprechend

stellen die in der **RME 1** erhobenen Daten und wissensbasierten Informationen den Ausgangspunkt des Referenzmodells dar. Ziel dieser Ebene ist es, instandhaltungsrelevante Datenquellen aus der Produktionsumgebung systematisch zu erfassen und in einer Form bereitzustellen, die eine konsistente Vorverarbeitung, Integration und Analyse unterstützt. Die Datenakquise ist dabei nicht als isolierter technischer Schritt zu verstehen, sondern als konzeptionell prägende Phase, in der wesentliche Voraussetzungen für die Qualität, Aussagekraft und Nutzbarkeit der gesamten Data Pipeline geschaffen werden. Im Kontext der vorliegenden Arbeit umfasst die Datenakquise sowohl die Erfassung expliziten und impliziten Domänenwissens als auch die sensorbasierte Erhebung strukturierter Messdaten mittels elektrischer Messtechnik. Diese beiden Datenquellen unterscheiden sich hinsichtlich ihrer Struktur, Entstehung und Granularität, sind jedoch komplementär zu betrachten. Während sensorische Messdaten objektive, zeitkontinuierliche Zustandsinformationen liefern, stellt Domänenwissen betriebsnahe Erfahrungswissen über Prozesse, typische Fehlerbilder und bewährte Instandhaltungsmaßnahmen bereit. Beide Perspektiven sind für datengetriebene Instandhaltungsansätze gleichermaßen relevant und müssen bereits auf Ebene der Datenakquise aufeinander abgestimmt werden.

Domänenwissen stellt eine wesentliche Informationsquelle für datengetriebene Instandhaltungsansätze dar, da es betriebsnahe Erfahrung, Prozessverständnis sowie Kenntnisse über typische Fehlerbilder und Instandhaltungsmaßnahmen umfasst (vgl. **Kapitel 3.3.1**). Im Kontext der **RME 1** wird Domänenwissen dabei nicht als Analyse- oder Entscheidungswissen verstanden, sondern als Ausgangsdatenquelle, deren Inhalte für die weitere Verarbeitung innerhalb der Data Pipeline digital verfügbar gemacht werden müssen. Ziel dieser Ebene ist es folglich, relevantes Expertenwissen systematisch zu erfassen und in eine persistente, maschinenlesbare Form zu überführen.

Domänenwissen liegt in Produktionsumgebungen häufig in impliziter Form vor und ist an einzelne Experten, wie Anlagenführer oder Instandhalter, gebunden. Dieses Wissen entsteht durch langjährige Erfahrung im Umgang mit Anlagen, durch die Beobachtung von Abweichungen im Betrieb sowie durch die Durchführung von Instandhaltungsmaßnahmen. Für eine kontinuierliche und skalierbare Nutzung innerhalb datengetriebener Systeme ist es erforderlich, dieses implizite Wissen zu externalisieren und in explizite Wissensquellen zu transformieren. Die Überführung von Expertenwissen in digitale Informationsquellen stellt somit einen zentralen Bestandteil der Datenerhebung im Kontext des Domänenwissens dar. Eine besondere Rolle nehmen hierbei organisatorische und technische Dokumentationsformen ein, insbesondere Anlagendokumentationen, Wartungsberichte, Instandhaltungsbücher sowie weitere schriftlich festgehaltene Erfahrungswerte (vgl. **Kapitel 3.2**). Diese Dokumente enthalten bereits explizit formuliertes Domänenwissen und bilden damit eine zentrale Brücke zwischen implizitem Expertenwissen und datengetriebenen Analyseverfahren. Gleichzeitig sind solche Dokumentationen in industriellen Umgebungen häufig historisch gewachsen, heterogen aufgebaut und in ihrer Struktur sowie Terminologie uneinheitlich ausgeprägt. Im Rahmen dieser Arbeit werden Anlagendokumentationen daher als primäre Wissensquelle betrachtet, deren systematische Nutzung jedoch bestimmte Anforderungen an die Datenerhebung voraussetzt.

Eine zentrale Voraussetzung für eine erfolgreiche Datenanalyse ist eine hohe Datenqualität, da diese maßgeblich die Aussagekraft und Stabilität datengetriebener Modelle beeinflusst (vgl. **Kapitel 3.4.1**). Während Maßnahmen zur Verbesserung der Datenqualität häufig in nachgelagerten Verarbeitungsschritten adressiert werden, wird die Qualität der Daten bereits bei ihrer Erhebung wesentlich geprägt. Insbesondere bei der manuellen Erfassung von Domänenwissen in Anlagendokumentationen oder Instandhaltungsbüchern entscheidet die Art und Weise der Dokumentation darüber, in welchem Umfang die Informationen später automatisiert ausgewertet und weiterverarbeitet werden können. Uneinheitliche Begrifflichkeiten, freie Textformate sowie fehlende strukturierende Merkmale führen dazu, dass umfangreiche Vorverarbeitungsschritte erforderlich werden, um die Daten für analytische Verfahren nutzbar zu machen. Dies erhöht nicht nur den zeitlichen und organisatorischen Aufwand, sondern kann auch zu Informationsverlusten oder Fehlinterpretationen führen. Vor diesem Hintergrund ist es für die **RME 1** erforderlich, bereits bei der Erfassung von Domänenwissen grundlegende Standards zu berücksichtigen, die eine konsistente Dokumentation unterstützen (vgl. **Kapitel 3.2**). Dazu zählen insbesondere ein vereinheitlichtes Wording, definierte Merkmale zur Zuordnung von Ereignissen zu Anlagen, Komponenten oder Zeiträumen sowie eine strukturierte Erfassung relevanter Kontextinformationen. Durch eine solche Standardisierung der Datenerhebung kann die Qualität der erfassten Informationen erhöht und der Aufwand in nachgelagerten Verarbeitungsschritten reduziert werden. Gleichzeitig wird die Grundlage für eine effizientere Informationsintegration sowie für eine verbesserte Nachvollziehbarkeit und Wiederverwendbarkeit von Analyseergebnissen geschaffen.

Darüber hinaus bildet die systematische Nutzung von Domänenwissen eine wesentliche Grundlage für kausal orientierte Analyse- und Modellierungsansätze innerhalb der intelligenten Data Pipeline. Während datengetriebene Verfahren statistische Zusammenhänge identifizieren können, ist die Interpretation dieser Zusammenhänge im Sinne von Ursache-Wirkungs-Beziehungen ohne domänenspezifisches Kontextwissen nur eingeschränkt möglich. Explizit erfasstes Domänenwissen unterstützt daher die Einordnung von Zustandsänderungen, Fehlermustern und Ereignissen in einen kausalen Zusammenhang und trägt dazu bei, beobachtete Effekte plausibel auf zugrunde liegende Ursachen zurückzuführen. Durch die frühzeitige Erhebung und strukturierte Bereitstellung von Domänenwissen wird somit eine Voraussetzung geschaffen, um prädiktive Modelle nicht ausschließlich korrelationsbasiert, sondern kausal informiert zu entwickeln und weiterzuentwickeln. Dies unterstützt insbesondere kausal-prädiktive Instandhaltungsansätze, bei denen Vorhersagen nicht nur auf statistischen Mustern beruhen, sondern durch domänenspezifisches Ursachenwissen ergänzt werden. In diesem Sinne leistet die Datenerhebung im Kontext des Domänenwissens einen wesentlichen Beitrag zur Zielsetzung der intelligenten Data Pipeline, da sie die Voraussetzungen schafft, um kausal informierte prädiktive Modelle weiterzuentwickeln und perspektivisch auch präskriptive Analyseansätze zu unterstützen.

Die **sensorbasierte Datenerhebung** stellt innerhalb der **RME 1** eine zentrale Quelle strukturierter und zeitkontinuierlicher Informationen dar. Durch die Erfassung physi-

kalischer Größen an Produktionsanlagen werden objektive Messwerte generiert, die den aktuellen Zustand sowie Veränderungen von Anlagenkomponenten abbilden (vgl. **Kapitel 3.1.3**). Diese Messwerte bilden die Grundlage für nachgelagerte Analyse- und Modellierungsprozesse innerhalb der intelligenten Data Pipeline. Im Kontext des Referenzmodells steht dabei nicht die konkrete Ausgestaltung messtechnischer Systeme im Vordergrund, sondern die Frage, unter welchen Rahmenbedingungen sensorische Daten erhoben werden müssen, um eine konsistente, qualitativ hochwertige und automatisiert weiterverarbeitbare Datenbasis zu schaffen. Die sensorbasierte Datenerhebung fungiert somit als Schnittstelle zwischen der physischen Produktionsumgebung und der datengetriebenen Verarbeitungsebene und trägt maßgeblich zur Verlässlichkeit der daraus abgeleiteten Zustands- und Prognosemodelle bei.

Die Qualität sensorbasierter Daten bildet eine zentrale Voraussetzung für die erfolgreiche Anwendung datengetriebener Analyse- und Modellierungsverfahren (vgl. **Kapitel 3.4.1**). Entsprechend ergeben sich für die **RME 1** spezifische Anforderungen an die Datenerhebung mittels elektrischer Messtechnik. Diese Anforderungen zielen darauf ab, eine konsistente, belastbare und für nachgelagerte Verarbeitungsschritte geeignete Datenbasis bereitzustellen. Eine grundlegende Anforderung besteht in der zielgerichteten Auswahl geeigneter Sensorik in Abhängigkeit von Prozess, Anlage und Anwendungsziel. Die eingesetzten Sensoren müssen in der Lage sein, relevante physikalische Größen mit ausreichender Genauigkeit, Auflösung und zeitlicher Dynamik zu erfassen, um Zustandsänderungen von Anlagenkomponenten zuverlässig abzubilden (vgl. **Kapitel 3.1.3**). Eine unzureichende oder nicht anwendungsadäquate Sensorauswahl kann die Aussagekraft der erhobenen Daten erheblich einschränken und wirkt sich unmittelbar auf die Qualität nachgelagerter Analyseergebnisse aus. Darüber hinaus ist eine zuverlässige und robuste Übertragung der erfassten Messwerte sicherzustellen. Hierzu sind geeignete Kommunikationsschnittstellen erforderlich, die eine kontinuierliche, verlustarme und zeitlich konsistente Datenübermittlung zwischen Sensorkomponenten und den nachgelagerten Verarbeitungseinheiten ermöglichen. Eine eindeutige zeitliche Referenzierung der Messdaten stellt dabei eine wesentliche Voraussetzung dar, um sensorische Daten mit weiteren Datenquellen innerhalb der Data Pipeline in Beziehung setzen zu können. Weiterhin ist sicherzustellen, dass die erhobenen Messwerte in standardisierten und konsistenten Datenformaten bereitgestellt werden (vgl. **Kapitel 3.4**). Die Verwendung gängiger Datentypen und einheitlicher Datenstrukturen erleichtert die Integration der Sensordaten in die Dateninfrastruktur und reduziert den Aufwand in nachgelagerten Vorverarbeitungs- und Integrationsschritten. Dadurch kann die Effizienz der gesamten Data Pipeline gesteigert und die Wiederverwendbarkeit der Daten für unterschiedliche Analyse- und Modellierungszwecke unterstützt werden.

Zusammenfassend lässt sich festhalten, dass die sensorbasierte Datenerhebung nicht isoliert betrachtet werden kann, sondern als integraler Bestandteil der intelligenten Data Pipeline zu verstehen ist. Die frühzeitige Berücksichtigung von Anforderungen an Sensorauswahl, Datenübertragung, Zeitbezug und Datenformate trägt wesentlich dazu bei, die Qualität der erhobenen Daten zu sichern und die Komplexität nachgelagerter Verarbeitungsschritte zu reduzieren. Auf diese Weise leistet die sensorbasierte Datenerhebung einen wesentlichen Beitrag zur Gesamtzielsetzung der intelligenten Data Pipeline, indem sie eine

belastbare und qualitativ hochwertige Datenbasis für Analyse- und Modellierungsansätze schafft.

Zusammenfassend bildet die **RME 1** die konzeptionelle Grundlage der intelligenten Data Pipeline, da sie maßgeblich über die Qualität, Interpretierbarkeit und Nutzbarkeit aller nachgelagerten Verarbeitungsschritte entscheidet. Für das Referenzmodell ergibt sich daraus die Anforderung, sowohl sensorbasierte Messdaten als auch explizit dokumentiertes Domänenwissen systematisch, konsistent und in maschinenlesbarer Form zu erfassen. Während die sensorische Datenerhebung eine zeitlich eindeutige, standardisierte und kontinuierlich verfügbare Datenbasis sicherstellen muss, ist Domänenwissen bereits auf Ebene der Erhebung so zu strukturieren, dass es für kausal informierte Analyse- und Modellierungsansätze nutzbar wird. Die **RME 1** ist damit nicht als rein technische Erfassungsstufe zu verstehen, sondern als qualitäts- und semantikprägende Ebene, die die Voraussetzungen für kausal-prädiktive Modelle schafft und zugleich die Weiterentwicklung hin zu präskriptiven Analyse- und Entscheidungsansätzen vorbereitet.

5.3 RME 2 - Vorverarbeitung und Bereitstellung

Für den Erfolg datengetriebener Analyse- und Modellierungsverfahren ist nicht allein die Erhebung von Daten entscheidend, sondern insbesondere deren Aufbereitung und Bereitstellung in einer hinreichend hohen Qualität (vgl. **Kapitel 3.3**). Unvollständige, verrauschte oder inkonsistente Daten wirken sich unmittelbar auf die Aussagekraft analytischer Ergebnisse aus und beeinträchtigen die Leistungsfähigkeit nachgelagerter Machine- und Deep-Learning-Modelle. Die **RME 2** adressiert daher alle Prozesse, die erforderlich sind, um heterogene Rohdaten in eine konsistente, qualitativ hochwertige und weiterverarbeitbare Form zu überführen.

Die Vorverarbeitung orientiert sich konzeptionell am ETL-Paradigma (Extract, Transform, Load) (vgl. **Kapitel 3.3.2**). Die **Extraktion** umfasst die Bereitstellung der in der vorhergehenden **RME 1** erhobenen Daten aus unterschiedlichen Quellen. Diese Daten können sich hinsichtlich Struktur, Format und Granularität erheblich unterscheiden. Ziel der **Transformationsphase** ist es, diese Rohdaten so aufzubereiten, dass sie für nachgelagerte analytische und modellgestützte Verfahren nutzbar sind. Dabei stehen nicht einzelne Algorithmen oder technische Implementierungen im Vordergrund, sondern die funktionale Wirkung der Vorverarbeitung auf Datenqualität, Konsistenz und Anschlussfähigkeit. Zentrale Aufgaben der Transformationsphase sind die Bereinigung fehlerhafter oder unvollständiger Daten, die Transformation in geeignete Repräsentationsformen, die Reduktion irrelevanter oder redundanter Attribute sowie die Integration mehrerer Datenquellen. Die Datenbereinigung dient der Identifikation und Behandlung von Störgrößen wie Rauschen, Ausreißern oder fehlenden Werten. Die Datentransformation zielt darauf ab, Daten in eine Form zu überführen, die eine effiziente Weiterverarbeitung ermöglicht, beispielsweise durch Vereinheitlichung von Wertebereichen oder Ableitung zusätzlicher Merkmale. Die Datenreduktion trägt dazu bei, die Komplexität der Datensätze zu verringern, ohne den Informationsgehalt für den betrachteten Anwendungsfall wesentlich zu beeinträchtigen. Die Datenintegration schließlich ermöglicht die Zusammenführung heterogener Datenquellen in

einer gemeinsamen Struktur.

Im Kontext des Referenzmodells ist dabei zwischen unterschiedlichen Datentypen zu unterscheiden. In dieser Arbeit werden zum einen Sensordaten in Form numerischer Zeitreihen aus Produktionsanlagen und zum anderen textbasierte Daten aus technischen Anlagendokumentationen betrachtet. Abhängig vom jeweiligen Datentyp ergeben sich unterschiedliche Anforderungen an die Vorverarbeitung. In **Abbildung 13** ist exemplarisch ein mögliches Vorgehensmodell zur Vorverarbeitung von Sensor- und Textdaten dargestellt, das sich an etablierten Ansätzen aus der Literatur orientiert [vgl. Vassiliadis et al. 2002, S.14-15; Lettner et al. 2014, S.1-2; Alam und Yao 2019, S.322-324; George et al. 2016, S.16-17; Hickman et al. 2022, S.121; Banks et al. 2018, S.453; Manning et al. 2008, S.30-32]. Die Abbildung dient dabei nicht der Festlegung eines verbindlichen technischen Vorgehens, sondern der Veranschaulichung typischer, datentypspezifischer Vorverarbeitungsschritte innerhalb der Referenzmodell-Ebene. Für Sensordaten lassen sich die allgemeinen Schritte der Transformationsphase des ETL-Prozesses anwenden, insbesondere in Bezug auf Datenbereinigung, Datentransformation, Datenreduktion und Datenintegration. Textdaten aus technischen Anlagendokumentationen weisen hingegen einen unstrukturierten Charakter auf und erfordern spezifische, sprachbezogene Vorverarbeitungsschritte. Die relevanten Textdaten liegen in dieser Arbeit als frei formulierte natürliche Sprache vor, weshalb die Vorverarbeitung darauf abzielt, diese in eine maschinell interpretierbare Form zu überführen. Exemplarisch umfasst dies die Vereinheitlichung der Groß- und Kleinschreibung, das Entfernen nicht-alphabetischer Zeichen, die Reduktion redundanter Informationen, das Entfernen häufig auftretender, semantisch wenig informativer Stopwörter sowie eine Lemmatisierung zur Überführung der Wörter in ihre Grundform. Nach Abschluss der Vorverarbeitung liegen sowohl Sensor- als auch Textdaten in einer Form vor, die für die Ablage in geeigneten Datenstrukturen und für die nachgelagerte Nutzung in Analyse- und Modellierungsprozessen geeignet ist.




Abbildung 13: Vorverarbeitung Sensordaten und Textdaten

Ein zentrales Gestaltungsprinzip der Vorverarbeitung und Bereitstellung ist die Nutzung des Zeitstempels als gemeinsame Referenzvariable. Durch die zeitliche Synchronisation können Sensordaten und textbasierte Informationen konsistent miteinander verknüpft

werden, wodurch eine integrierte Betrachtung technischer Zustände, historischer Ereignisse und dokumentierter Maßnahmen ermöglicht wird. Die zeitliche Referenz bildet damit eine wesentliche Voraussetzung für die nachgelagerte Datenintegration. Darüber hinaus kommt der Einbindung von Domänenexperten eine besondere Bedeutung zu, da sie maßgeblich zur Steigerung der Datenqualität beiträgt [vgl. Petrović et al. 2017, S.433-434; Tahir und Brezillon 2011, S.720]. Fachliches Wissen ist notwendig, um Vorverarbeitungsschritte zielgerichtet auszugestalten, Daten im Anwendungskontext korrekt zu interpretieren und sicherzustellen, dass die aufbereiteten Daten die relevanten Aspekte des betrachteten Systems abbilden. Die Vorverarbeitung ist daher nicht als rein technischer Prozess zu verstehen, sondern als fachlich gestützter Schritt innerhalb der intelligenten Data Pipeline. Nach Abschluss der Transformationsphase erfolgt das **Laden**. Hier werden die aufbereiteten Daten in geeigneten Datenstrukturen abgelegt und für die nachgelagerte **RME 3** bereitgestellt. Die Bereitstellung erfolgt so, dass die Daten unmittelbar für Integrations-, Analyse- und Modellierungsprozesse genutzt werden können, ohne zusätzliche, nicht vorgesehene Aufbereitungsschritte zu erfordern.

Aus der Betrachtung der **RME 2** ergibt sich, dass die Aufbereitung der Daten entlang eines systematischen und reproduzierbaren Prozesses erfolgen muss, um eine konsistente Datenqualität unabhängig von konkreten technischen Implementierungen sicherzustellen. Die vorverarbeiteten Daten sind dabei in einer standardisierten und weiterverarbeitbaren Form bereitzustellen, sodass sie ohne zusätzliche Anpassungen in nachgelagerte Integrations-, Analyse- und Modellierungsprozesse überführt werden können. Eine hohe Datenqualität ist als zentrale Zielgröße der Vorverarbeitung zu verstehen und erfordert sowohl technische Maßnahmen zur Behandlung von Störgrößen als auch die fachliche Bewertung der Daten im Anwendungskontext. Darüber hinaus muss die Vorverarbeitung die Integration heterogener Datenquellen unterstützen, wobei dem Zeitstempel als gemeinsamer Referenzvariable eine besondere Bedeutung für die konsistente Zusammenführung der Daten zukommt. Die Einbindung von Domänenexperten ist hierbei als integraler Bestandteil des Vorverarbeitungsprozesses zu berücksichtigen, da fachliches Wissen wesentlich zur zielgerichteten Transformation und Interpretation der Daten beiträgt. Insgesamt ist sicherzustellen, dass die Vorverarbeitung und Bereitstellung der Daten nahtlos an die nachgelagerte **RME 3** anschließt und eine belastbare Grundlage für analytische und modellgestützte Verfahren bildet.

5.4 RME 3 - Informationsintegration

Die **RME 3** bündelt alle Funktionen, die erforderlich sind, um die in den vorhergehenden Ebenen erhobenen und vorverarbeiteten Daten systematisch zusammenzuführen, kontextualisiert bereitzustellen und als konsistente Grundlage für nachgelagerte Analyse- und Entscheidungsprozesse nutzbar zu machen. Während die Datenintegration im engeren Sinne primär die technische Zusammenführung heterogener Datenquellen adressiert, erweitert die Informationsintegration diese Perspektive um eine inhaltliche und domänenspezifische Verknüpfung der Daten. Ziel ist damit nicht allein die Aggregation von Datenbeständen, sondern die Bereitstellung eines Datenfundaments, in dem relevante Beziehungen zwischen Datenpunkten, Zuständen und Ereignissen explizit zugänglich und interpretierbar sind.

Diese Sichtweise steht im Einklang mit dem Verständnis von Informationsintegration als Voraussetzung zur Abbildung kausaler Zusammenhänge, wie sie in der Literatur als Grundlage intelligenter, wissensbasierter Systeme beschrieben wird [vgl. Genesereth et al. 1997, S.121; Tononi 2010, S.300-302].

Insbesondere im Kontext kausal-prädiktiver Analyseansätze ist diese Ebene von zentraler Bedeutung, da hierfür nicht nur Messwerte vorliegen müssen, sondern deren Bedeutung im Systemzusammenhang nachvollziehbar und semantisch abgesichert sein muss. Entsprechend ergibt sich für die intelligente Data Pipeline die Notwendigkeit einer Datenhaltungs- und Integrationslogik, die heterogene Datentypen gemeinsam verwalten, zeitlich und semantisch harmonisieren und für unterschiedliche Nutzergruppen und analytische Arbeitsvorgänge bereitstellen kann. Auf Ebene des Referenzmodells bleibt diese Ausgestaltung bewusst technologieunabhängig, wobei konkrete Architekturalternativen und Datenplattformkonzepte werden im Grundlagenkapitel systematisch eingeordnet (vgl. **Kapitel 3.4.2**). Für die hier beschriebene Ebene ist vielmehr entscheidend, dass eine Integrationsinstanz existiert, die Daten persistent speichert, Metadaten zur Nachvollziehbarkeit verwaltet und die Daten in geeigneten Sichten für Analyse- und Wissenskomponenten bereitstellt.

Ein zentraler funktionaler Bestandteil der Informationsintegration ist die Unterstützung domänenspezifischer Annotation- und Labeling-Prozesse. Labeling beziehungsweise Datenannotation beschreibt die Zuweisung von Zustands- oder Ereignislabeleds zu Datenpunkten, um datengetriebene Lernverfahren in die Lage zu versetzen, Muster zu erkennen und belastbare Vorhersagen abzuleiten [vgl. H.-L. Chen et al. 2008, S.1458-1459; Cao und Liang 2011, S.2381-2382; Kulesza et al. 2014, S.3075-3076; D. Wu et al. 2020, S.3-4]. Die Referenzmodell-Ebene muss daher Mechanismen vorsehen, mit denen Domänenwissen strukturiert und nachvollziehbar in die Datenbasis überführt werden kann. Dies kann beispielsweise über **manuelles Labeling mittels Annotationswerkzeugen** erfolgen, bei dem Domänenexperten einzelne Datenabschnitte direkt klassifizieren [vgl. Settles 2009, S.3-4]. Solche Verfahren liefern in der Regel semantisch präzise Labels, sind jedoch aufgrund des hohen zeitlichen und personellen Aufwands nur begrenzt skalierbar. Als vermittelnder Ansatz können **Human-in-the-Loop**-Konzepte integriert werden, bei denen maschinell erzeugte Vorschläge iterativ durch Experten validiert und verbessert werden [vgl. Sobot et al. 2024, S.1-2; López-Meneses et al. 2025, S.3-4]. Diese Form der Interaktion reduziert den manuellen Aufwand und erhöht gleichzeitig die Robustheit der Modelle, da menschliches Fachwissen gezielt in den Lernprozess eingebunden bleibt [vgl. Mosqueira-Rey et al. 2023, S.3044-3045]. Für eine weitergehende Skalierung der Labeling-Prozesse können zudem **regelbasierte** oder **schwach überwachende** Ansätze vorgesehen werden, bei denen Domänenwissen in Form von Heuristiken oder sogenannter Labeling-Funktionen formalisiert und automatisiert auf große Datenmengen angewendet wird [vgl. Ratner et al. 2020, S.714; Shin et al. 2021, S.1-2]. Da diese Verfahren potenziell verrauschte oder inkonsistente Labels erzeugen, ist innerhalb der Informationsintegration zugleich eine Qualitätssicherung erforderlich, etwa durch Aggregationsmechanismen, Konfliktauflösung und die transparente Dokumentation der Labelherkunft [vgl. J. Zhang et al. 2022, S.1-2]. Ergänzend können **visuelle, explorative Annotation-Workflows** eingesetzt werden, die Domänenexperten über spezialisierte Dashboards eine interaktive Bewertung und Annotation von Daten er-

möglichen [vgl. Grimmeisen et al. 2023, S.5099; Bouchakwa et al. 2020, S.21690-21691]. Darüber hinaus kann Labeling auch auf **Metadaten-** und **Governance-**Ebene erfolgen, indem Datensätze strukturell klassifiziert werden, etwa hinsichtlich Relevanz, Qualität oder regulatorischer Anforderungen [vgl. Gdanitz et al. 2023, S.1-2][S.83297-83298]. Diese Form der Annotation dient weniger der feingranularen Zustandsbeschreibung einzelner Datenpunkte, erhöht jedoch Transparenz, Wiederverwendbarkeit und Compliance innerhalb komplexer Datenlandschaften [vgl. Kropshofer et al. 2025, S.83310]. Jedoch geht die Integration von Datenkatalogen einher mit hohen Implementierungs- und Wartungskosten sowie der komplexen Handhabung [vgl. Boufassil et al. 2023, S.374].

Die Qualität maschinellen Lernens hängt maßgeblich von der Qualität und Konsistenz der Labels im Trainingsdatensatz ab. Vor diesem Hintergrund zeigt **Tabelle 8** eine strukturierte Gegenüberstellung zentraler Labeling-Ansätze, wie sie in Wissenschaft und Praxis etabliert sind [vgl. Pavoni et al. 2022, S.246-247; vgl. Settles 2009, S.2-7; vgl. Andriluka et al. 2018, S.2; Sobot et al. 2024, S.2-3; López-Meneses et al. 2025, S.3-5; Mosqueira-Rey et al. 2023, S.3043-3044; Ratner et al. 2020, S.709-711; Shin et al. 2021, S.1-2; J. Zhang et al. 2022, S.1-2; Grimmeisen et al. 2023, S.5100-5101; Bouchakwa et al. 2020, S.21724-21727; Yang et al. 2025, S.11-19; Gdanitz et al. 2023, S.1-2; Kropshofer et al. 2025, S.83305-83306; Boufassil et al. 2023, S.374-375]. Die Übersicht dient dabei nicht der methodischen Bewertung einzelner Verfahren, sondern verdeutlicht die Heterogenität der Labeling-Strategien in Bezug auf Skalierbarkeit, Qualitätsniveau und erforderliche Domänenexpertise. Für das Referenzmodell der intelligenten Data Pipeline ist diese Gegenüberstellung insbesondere insofern relevant, als sich daraus funktionale Anforderungen an die Informationsintegrationsebene ableiten lassen. Da unterschiedliche Labeling-Ansätze unterschiedliche Interaktions-, Speicher- und Governance-Anforderungen implizieren, muss **RME 3** so gestaltet sein, dass sowohl manuelle als auch teil- oder regelbasierte Verfahren unterstützt und nachvollziehbar integriert werden können. Die Tabelle bildet damit eine analytische Grundlage für die Ausgestaltung der Informationsintegration, ohne einzelne Methoden normativ vorzugeben.

Neben dem Labeling ist die Rückkopplung zur Wissenskomponente des Gesamtsystems ein wesentliches Element der Informationsintegration. Die integrierte Ebene stellt nicht nur Daten für analytische Modelle bereit, sondern unterstützt zugleich die Entstehung eines lernenden Systems, in dem Labels, Zustandsdiagnosen und Ereigniszuordnungen, die im Betrieb entstehen, als strukturierte Information in Richtung der Wissensdatenbank überführt werden. Umgekehrt kann bereits vorhandenes Erfahrungswissen in Form historischer Schadensbilder, dokumentierter Ursachen-Wirkungs-Beziehungen oder bewährter Instandhaltungsmaßnahmen den Labeling-Prozess unterstützen und semantisch absichern. Darüber hinaus können die in der **RME 3** konsolidierten und angereicherten Daten auch unmittelbar zur Unterstützung präskriptiver Entscheidungsprozesse genutzt werden. Insbesondere ermöglichen vergangene Ereignisse, deren Ursachenanalysen sowie die zugehörigen Lösungs- und Maßnahmenhistorien eine fallbasierte Ableitung von Handlungsempfehlungen. Da diese Informationen zugleich als Grundlage für das Labeling herangezogen werden, entsteht eine konsistente Verbindung zwischen Datenannotation, Modelltraining und Entscheidungsunterstützung. Die Informationsintegrationsebene fungiert damit nicht nur als vorbereitende Instanz für analytische Verfahren, sondern als vermittelnde Schicht, in der

Tabelle 8: Vergleich von Labeling-Methoden

Methoden	Stärken	Schwächen	Expertenbedarf
Manuelles Labeling über Annotationstools	Sehr präzise und flexibel bei komplexen Daten; hohe Labelqualität	Sehr zeit- und ressourcenintensiv; Skalierbarkeit eingeschränkt	Sehr hoch
Human-in-the-Loop-Systeme (z. B. Active Learning)	Effizienter als rein manuelles Labeling; gezielte Nutzung von Expertenressourcen	Modellabhängig; initial aufwendig in Setup und Infrastruktur	Mittel bis hoch (gezielt)
Regelbasierte Labelgenerierung (Weak Supervision)	Schnelle Labelgenerierung; gut skalierbar; kosteneffizient	Fehlerrisiko bei komplexen Mustern; regelmäßige Pflege notwendig	Mittel
Visuelle Annotation-Workflows (Assistierte Tools)	Benutzerfreundlich; schnelles Labeling durch Modellunterstützung; gute Balance aus Präzision und Effizienz	Qualität abhängig von Vorhersagemodellen; Schulungsaufwand	Mittel bis hoch
Labeling im Metadaten- und Governance-Layer	Integriert in Datenmanagement; automatisch generierbare Metainformationen; compliance-fähig	Eingeschränkt für feinkörnige Aufgaben; hohe technische Komplexität	Niedrig bis mittel

operative Erfahrungswerte, modellbasierte Erkenntnisse und historische Lösungsstrategien zusammengeführt werden. Durch diese enge Verzahnung wird die Voraussetzung geschaffen, eine präskriptive Entscheidungsunterstützung schrittweise aufzubauen. Die resultierenden Empfehlungen stützen sich dabei nicht ausschließlich auf abstrakte Modellvorhersagen, sondern werden durch empirisch belegte vergangene Ereignisse und dokumentierte Maßnahmen ergänzt. Auf diese Weise trägt die **RME 3** dazu bei, den Übergang von kausal-prädiktiven Analysen hin zu fundierten, kontextsensitiven **RME 6** vorzubereiten.

Aus der Rolle der Informationsintegration im Gesamtkonzept folgt, dass diese Ebene eine konsistente und nachvollziehbare Zusammenführung heterogener Datenquellen sicherstellen muss und dabei nicht auf technische Integrationsaufgaben reduziert werden darf. Vielmehr bildet sie die Brücke zwischen Datenbasis, Domänenwissen und analytischer Nutzung. Insbesondere ist sicherzustellen, dass Domänenexperten in geeigneter Form in Integrations- und Labeling-Prozesse eingebunden werden können, ohne dass dies ausschließlich als nicht skalierbarer manueller Schritt ausgelegt ist. Gleichzeitig muss die Architektur die Rückführung integrierter Daten und erzeugter Metainformationen in die Wissensdatenbank unterstützen, sodass eine geschlossene Rückkopplung zwischen Daten, Modellen und Wissen entsteht. Auf diese Weise wird die Grundlage für robuste kausal-prädiktive Analysen geschaffen und zugleich der Übergang zu weiterführenden, präskriptiven Entscheidungslogiken vorbereitet.

5.5 RME 4 - Analyse

Das Data-Mining-Prozessmodell CRISP-DM sowie verwandte Vorgehensmodelle wie KDD oder wissensgetriebene Projektablaufe strukturieren datenanalytische Vorhaben entlang eines iterativen Gesamtprozesses, der von der Zieldefinition über die Modellentwicklung bis hin zur Bereitstellung und Nutzung der Analyseergebnisse reicht (vgl. **Kapitel 3.3**). Die Phase der Bereitstellung markiert innerhalb dieser Modelle jedoch keinen Abschluss der Datenanalyse, sondern den Übergang von einer entwicklungsorientierten Modellbildung in einen anwendungs- und betriebsspezifischen Nutzungskontext. Dieser Übergang wird im Referenzmodell der intelligenten Data Pipeline explizit aufgegriffen und in der Analyseebene (**RME 4**) konzeptionell verankert. In dieser Ebene werden die zuvor trainierten und validierten Machine- und Deep-Learning-Modelle auf einer geeigneten Rechner- und Systeminfrastruktur in der Fabrikumgebung implementiert und in die bestehende Produktions- und Informationslandschaft integriert. Die Modelle werden dort kontinuierlich mit Echtzeit- und Prozessdaten aus den Produktionsanlagen versorgt, sodass sie dauerhaft im operativen Betrieb eingesetzt werden können. Ziel der Analyseebene ist es folglich nicht, die Modellentwicklung fortzuführen, sondern die stabile und reproduzierbare Ausführung der Modelle unter realen Einsatzbedingungen sicherzustellen und fortlaufend Analyseergebnisse zu erzeugen, die den aktuellen Systemzustand widerspiegeln. Gleichzeitig bildet die Analyseebene eine zentrale Rückkopplungsschicht innerhalb der intelligenten Data Pipeline. Die im produktiven Betrieb gewonnenen Ergebnisse und Beobachtungen ermöglichen eine kontinuierliche Bewertung der Modellgüte und liefern die Grundlage für weiterführende Anpassungs- und Weiterentwicklungsprozesse in den vorgelagerten Ebenen. Auf diese Weise wird der in prozessualen Modellen wie CRISP-DM, KDD und wissensgetriebenen Vorgehensmodellen angelegte zyklische Charakter datengetriebener Analyseprozesse im Rahmen der intelligenten Data Pipeline systematisch auf den produktiven Betrieb übertragen und architektonisch abgesichert.

Die **Modellbereitstellung** stellt die Schnittstelle zwischen der experimentellen Entwicklungsumgebung und dem produktiven Einsatzkontext dar und bildet damit einen kritischen Übergang innerhalb des Lebenszyklus von Machine- und Deep-Learning-Modellen [vgl. Ashmore et al. 2022, S.3–6]. Während in der Entwicklungs- und Evaluationsphase primär die methodische Validität und die Leistungsfähigkeit eines Modells anhand definierter Metriken im Vordergrund stehen, rücken in der Analyseebene Anforderungen an eine robuste, effiziente und skalierbare Integration in bestehende Informationssysteme in den Fokus [vgl. A. Kumar und Priyadarshini 2025, S.5829; Zheng et al. 2024, S.1]. Abhängig vom infrastrukturellen Rahmen und vom Anwendungsfall können unterschiedliche Bereitstellungsformen zum Einsatz kommen. Dazu zählen unter anderem die Bereitstellung von Modellen über Application Programming Interfaces (APIs) zur Nutzung durch externe Anwendungen sowie die Integration in eingebettete Systeme mit begrenzten Hardware-Ressourcen [vgl. Ofoeda et al. 2019, S.76–77; Batzolis et al. 2023, S.345–347; Gupta und Ragala 2024, S.270–271]. Jede dieser Bereitstellungsstrategien ist mit spezifischen Herausforderungen hinsichtlich Ressourcenverbrauch, Latenzzeiten, Ausfallsicherheit und Wartbarkeit verbunden [vgl. Pramod Singh 2021, S.59–61; P. Xu et al. 2021, S.1–2]. Neben funktionalen Aspekten sind insbesondere nicht-funktionale Anforderungen von zentraler

Bedeutung. Hierzu zählen Skalierbarkeit, Fehlertoleranz, Sicherheits- und Datenschutzmechanismen sowie die langfristige Wart- und Erweiterbarkeit der Systemarchitektur [vgl. Amarasinghe 2024, S.2; Gilmore et al. 2011, S.308; Razavi et al. 2024, S.1–2; Tarafdar 2025, S.393–395]. Diese Anforderungen beeinflussen maßgeblich die Akzeptanz und Nachhaltigkeit der eingesetzten Modelle im produktiven Betrieb [vgl. Karamitsos et al. 2020, S.8–10].

Das **Modellmonitoring** und das **Nachtrainieren** stellen keine abgeschlossene Phase dar, sondern einen kontinuierlich fortlaufenden Bestandteil der Analyseebene, der die langfristige Funktionsfähigkeit der Modelle unter realen Einsatzbedingungen sicherstellt [vgl. Paleyes et al. 2023, S.12–14]. Zentrales Element ist die fortlaufende Überwachung von Leistungsmetriken, die bereits in der Evaluationsphase zur Beurteilung der Modellgüte herangezogen wurden [vgl. Karamitsos et al. 2020, S.8–10; T. Schröder und M. Schulz 2022, S.111–113]. Im produktiven Betrieb unterliegen sowohl die Eingabedaten als auch die zugrunde liegenden Systemzusammenhänge dynamischen Veränderungen. Diese können sich in Form von Data Drift, also Änderungen in den statistischen Eigenschaften der Eingabedaten, oder Concept Drift, also Änderungen in den Zusammenhängen zwischen Eingabe- und Zielvariablen, manifestieren [vgl. Ackerman et al. 2020, S.1–3; Rahmani et al. 2023, S.2; Jourdan et al. 2023, S.33–34; Zenisek et al. 2019, S.1–2]. Werden solche Effekte nicht frühzeitig erkannt, kann es zu einer schrittweisen Verschlechterung der Modellleistung kommen, was Fehlentscheidungen und eine eingeschränkte Nutzbarkeit der Analyseergebnisse zur Folge hat. Um diesen Effekten entgegenzuwirken, ist ein systematisches Nachtrainieren der Modelle erforderlich [vgl. Mahadevan und Mathioudakis 2023, S.1–3; Mallick et al. 2022, S.77–78]. Das Nachtrainieren kann in unterschiedlichen Formen erfolgen, etwa als periodisches Retraining in festgelegten Intervallen, als inkrementelles Lernen mit kontinuierlicher Datenintegration oder als ereignisgesteuertes Retraining bei detektierten Leistungseinbußen [vgl. Chitraju Gopal Varma 2025, S.5–7; Kanda et al. 2023, S.732]. Die **RME 4** übernimmt hierbei die Aufgabe, die Leistungsfähigkeit der eingesetzten Modelle unter produktiven Einsatzbedingungen kontinuierlich zu überwachen und Abweichungen infolge von Data Drift oder Concept Drift zu identifizieren. Die daraus resultierende Notwendigkeit einer Modellanpassung ergibt sich implizit aus der Analyse der Modellgüte und stellt eine fachlich bekannte Konsequenz im Lebenszyklus datengetriebener Modelle dar. Die konkrete Durchführung des Nachtrainierens ist jedoch nicht Bestandteil der Analyseebene, sondern wird in der Modellierungsebene (**RME 7**) verortet, in der entsprechende Trainings- und Validierungsprozesse umgesetzt werden.

Ein adäquat konzipierter Analyseprozess umfasst neben der technischen Integration der Modelle auch deren Einbettung in ein übergreifendes **Machine-Learning-Operations-Framework (MLOps)** [vgl. Kreuzberger et al. 2023, S.31872–31876; Singla 2023, S.335–336; Hewage und Meedeniya 2022, S.2–3]. MLOps-Ansätze unterstützen eine kontinuierliche Bereitstellung, ein systematisches Monitoring sowie das reproduzierbare Nachtrainieren von Modellen. Durch die Integration von Modell- und Datenversionierung, automatisierten Trainingspipelines und Continuous-Deployment-Mechanismen wird sichergestellt, dass Anpassungen transparent, nachvollziehbar und effizient durchgeführt werden können [vgl. van der Weide et al. 2017, S.1–2; Heil et al. 2021, S.1133–1135;

Mahida 2021, S.1967–1968].

Die in der **RME 4** erzeugten Modellergebnisse stellen jedoch keinen Selbstzweck dar, sondern bilden die Grundlage für eine kontinuierliche Beobachtung und Bewertung des Anlagen- und Systemzustands. Entsprechend ist die **RME 4** funktional mit der Überwachungsebene (**RME 5**) gekoppelt, in der die durch die Modelle generierten Ergebnisse, aufbereitet, visualisiert und für unterschiedliche Nutzergruppen zugänglich gemacht werden. Während die **RME 4** die algorithmische Verarbeitung und Bewertung der eingehenden Echtzeitdaten übernimmt, liegt der Fokus der **RME 5** auf der transparenten Darstellung, Aggregation und zeitlichen Einordnung dieser Ergebnisse. Auf diese Weise wird eine kontinuierliche Beobachtbarkeit des Systemverhaltens ermöglicht, ohne dass die analytische Modelllogik selbst Bestandteil der Visualisierungs- oder Monitoringkomponenten ist. Die Trennung dieser Verantwortlichkeiten trägt zur Modularität der intelligenten Data Pipeline bei und unterstützt sowohl die Skalierbarkeit als auch die Nachvollziehbarkeit der Analyseergebnisse im Betrieb.

Aus den dargestellten Zusammenhängen ergeben sich für die **RME 4** der intelligenten Data Pipeline mehrere zentrale Anforderungen. Dazu zählt zunächst die Bereitstellung einer robusten und skalierbaren Infrastruktur zur Modellimplementierung und -integration, die eine nahtlose Überführung der in der Modellierungsebene entwickelten Modelle in die Produktionsumgebung gewährleistet. Ebenso ist ein kontinuierliches Modellmonitoring erforderlich, das Leistungsabweichungen infolge von Veränderungen in den Eingabedaten oder den zugrunde liegenden Systemzusammenhängen frühzeitig erkennt und transparent macht. Auf Basis dieser Beobachtungen muss ein strukturierter Mechanismus vorgesehen werden, der den Bedarf an einem Nachtrainieren der Modelle identifiziert und an die dafür vorgesehene Modellierungsebene rückkoppelt, um die Modellgüte über den gesamten Lebenszyklus hinweg abzusichern. Darüber hinaus ist sicherzustellen, dass die in der Analyseebene erzeugten Modellergebnisse in einer strukturierten und standardisierten Form bereitgestellt werden, sodass sie von der nachgelagerten Überwachungsebene für Visualisierungs-, Monitoring- und Alarmierungszwecke genutzt werden können. Schließlich ist die Analyseebene in ein konsistentes MLOps-Konzept einzubetten, das den operativen Betrieb der Modelle langfristig wartbar, reproduzierbar und anpassungsfähig gestaltet.

5.6 RME 5 - Überwachung

Die **RME 5** bildet innerhalb der intelligenten Data Pipeline die operative Schnittstelle zwischen der kontinuierlichen datenbasierten Analyse und der strategischen Entscheidungsunterstützung. Ihr Ziel besteht darin, die Ergebnisse der modellbasierten Analysen fortlaufend zu erfassen, aufzubereiten, zu bewerten und in einer für unterschiedliche Nutzergruppen verständlichen Form bereitzustellen. Damit stellt sie den Übergang von der rein analytischen Ergebniserzeugung zur nutzungsorientierten Interpretation und Handlungsvorbereitung sicher und leistet einen zentralen Beitrag zur Umsetzung einer präskriptiven Instandhaltungsstrategie.

Die in der **RME 4** eingesetzten Machine- und Deep-Learning-Modelle entfalten ihren praktischen Nutzen erst dann vollständig, wenn ihre Ergebnisse transparent, nachvollziehbar und kontextualisiert kommuniziert werden [vgl. Konzack et al. 2019, S.207–208].

Die **Visualisierung** übernimmt hierbei die Rolle eines vermittelnden Elements zwischen der technisch geprägten Modellverarbeitung und der menschlichen Entscheidungsfindung [vgl. Burnay et al. 2019, S.853–855; Qianwen Wang et al. 2022, S.5134]. Sie dient dazu, hochdimensionale, häufig abstrakte Modelloutputs so zu verdichten, dass sie verständlich interpretiert und handlungsleitend genutzt werden können [vgl. Fu et al. 2019, S.127]. Gleichzeitig ist sicherzustellen, dass Visualisierungen klar strukturiert, konsistent und auf die jeweilige Nutzungssituation abgestimmt sind, da eine ungeeignete Darstellung oder die Auswahl irrelevanter Kennzahlen die Interpretierbarkeit der Ergebnisse erheblich beeinträchtigen kann [vgl. Rahman et al. 2017, S.1]. Zentrale Gestaltungsprinzipien betreffen insbesondere die kognitive Entlastung der Anwender sowie die Vermeidung visueller Überladung [vgl. Yigitbasioglu und Velcu 2012, S.42–43; Few 2006, S.39–40; Bach et al. 2023, S.343–344]. Darüber hinaus ist die Einbettung der Visualisierungslösungen in bestehende organisatorische Prozesse und Informationsstrukturen eine wesentliche Voraussetzung für ihre Wirksamkeit [vgl. Gami et al. 2024, S.43]. Die dargestellte Informationsmenge ist dabei bewusst zu begrenzen, da eine übermäßige Datenfülle die Übersichtlichkeit reduziert und den Entscheidungsprozess erschwert [vgl. Janes et al. 2013, S.17–18]. Ein ausgewogenes Verhältnis zwischen funktionalen und visuellen Eigenschaften ist ebenso erforderlich wie Konsistenz, klare Gruppierung, zeitliche Ordnung und strukturierte Anordnung der dargestellten Inhalte [vgl. Yigitbasioglu und Velcu 2012, S.46; Sarikaya et al. 2018, S.683–684; Bernard et al. 2019, S.1619–1621].

In der praktischen Umsetzung kommen unterschiedliche Visualisierungskonzepte zum Einsatz. Semantisch reduzierte Darstellungen, etwa Ampel- oder Scoring-Systeme, ermöglichen eine schnelle Einschätzung kritischer Zustände, bergen jedoch das Risiko einer Übervereinfachung, bei der Unsicherheiten und feine Abstufungen verloren gehen [vgl. Dowding und Merrill 2018, S.514; Fallucchi et al. 2019, S.141–142; Feldschmid 2009, S.30–31; Greving 2009, S.69; Oehlerking 2024, S.100–102]. Interaktive Dashboards erlauben hingegen eine kontextsensitive Exploration der Analyseergebnisse und unterstützen sowohl aggregierte Übersichten als auch detaillierte Fachexpertendiagnosen [vgl. Burch und Schmid 2023, S.63–66; Al-Hajj et al. 2013, S.5]. Gleichzeitig besteht hier die Gefahr kognitiver Überlastung, wenn Interaktionsmöglichkeiten und Kennzahlen nicht klar strukturiert sind [vgl. Nadj et al. 2020, S.2–4; Alhamadi 2020, S.368–369]. Ergänzend können narrative Visual-Analytics-Ansätze eingesetzt werden, bei denen klassische Visualisierungen durch automatisch generierte Textzusammenfassungen ergänzt werden, um Modellentscheidungen sprachlich zu erläutern und zentrale Einflussgrößen hervorzuheben [vgl. Segel und Heer 2010, S.1139–1140; Hullman und Diakopoulos 2011, S.2233]. Diese Ansätze fördern insbesondere die Akzeptanz in nicht-technischen Kontexten, sind jedoch stark von der Qualität der zugrunde liegenden Natural-Language-Generation, die die automatisch Erzeugung von natürlichsprachlichen Texten aus strukturierten Daten darlegt, abhängig [vgl. Hoque und Islam 2025, S.1–2].

Die präskriptive Instandhaltung, deren Reife- und Komplexitätsgrad im Vergleich zu anderen Instandhaltungsstrategien als besonders hoch eingestuft wird, verfolgt das Ziel, durch die systematische Ableitung von Handlungsempfehlungen eine optimale Durchfüh-

rung von Instandhaltungsmaßnahmen zu unterstützen (vgl. **Kapitel 3.1.3**). Während Machine- und Deep-Learning-Modelle primär auf die Generierung belastbarer prädiktiver Aussagen ausgerichtet sind, entfaltet sich ihr praktischer Nutzen erst durch die Überführung dieser Prognosen in konkrete, handlungsorientierte Entscheidungen [vgl. Bertsimas und Kallus 2020, S.1025–1026]. Die Transformation von Vorhersagen in Maßnahmen stellt damit einen zentralen Bestandteil moderner Entscheidungsunterstützungssysteme dar und markiert den Übergang von prädiktiven zu präskriptiven Analyseansätzen. Die **RME 5** stellt die operative Sicht auf die Ergebnisse der **RME 4** dar. Ihre zentrale Funktion besteht in der kontinuierlichen Visualisierung und Aufbereitung der durch die **RME 5** erzeugten Modelloutputs sowie in deren Einordnung mithilfe des in der Wissensbasis (**RME 6**) abgelegten Erfahrungs- und Entscheidungswissens. In **RME 5** werden somit aktuelle, kausal-prädiktive Analyseergebnisse mit historisch gewachsenen Wissensstrukturen verknüpft und in geeigneter Form visualisiert. Ziel ist es, den aktuellen Anlagen- und Prozesszustand transparent darzustellen und diesen in Anbetracht vergangener Ereignisse, dokumentierter Ursachen und bewährter Maßnahmen interpretierbar zu machen. Die **RME 5** fungiert damit als Schnittstelle zwischen datengetriebener Analyse und menschlicher Entscheidungsfindung. Durch die visuelle Kopplung von prädiktiven Modellergebnissen mit explizitem Domänenwissen entsteht ein erweiterter Entscheidungsraum, der kausal informierte Einschätzungen ermöglicht und zugleich den Übergang zu präskriptiven Ansätzen vorbereitet. Die eigentliche Wissensgenerierung und -konsolidierung verbleibt dabei in der Wissensbasis (**RME 6**), während **RME 5** dieses Wissen situationsbezogen nutzt, kommuniziert und handlungsrelevant macht.

In der Literatur werden unterschiedliche methodische Ansätze zur Ableitung von Handlungsempfehlungen beschrieben, die in der Überwachungsebene genutzt werden können. Regelbasierte Systeme verknüpfen Modellvorhersagen mit vordefinierten Entscheidungslogiken und ermöglichen eine direkte Übersetzung von Prognosen in Maßnahmen [vgl. B. Silva et al. 2023, S.880–882]. Ein typisches Anwendungsbeispiel ist die prädiktive Instandhaltung, bei der geschätzte Restlebensdauern unmittelbar in Wartungsstrategien überführt werden [vgl. W. Zhang et al. 2019, S.2021–2022]. Darüber hinaus integrieren optimierungsbasierte Verfahren Modellergebnisse in mathematische Entscheidungsmodelle, um unter Berücksichtigung von Kosten, Risiken und Ressourcenrestriktionen geeignete Maßnahmen abzuleiten [vgl. Blanco 2020, S.39–41; Geoffrion und Maturana 1995, S.1; Fanti et al. 2015, S.86–87; Suchánek et al. 2021, S.8–10; Bakhrankova 2010, S.591–592]. Ergänzend gewinnen erklärbare Empfehlungssysteme an Bedeutung, die auf Methoden der Explainable AI aufbauen und Handlungsempfehlungen transparent begründen, indem sie relevante Einflussfaktoren offenlegen [vgl. Angelov et al. 2021, S.5–6; Minh et al. 2022, S.3503–3504].

Für die operative Nutzung dieser Empfehlungen ist deren Einbettung in geeignete Visualisierungs- und Entscheidungsunterstützungskonzepte erforderlich. Dazu zählen unter anderem Schwellenwertdefinitionen oder Szenarienanalysen zur Auslösung von Empfehlungen sowie nutzerzentrierte Interfaces, die Empfehlungen kontextualisiert und verständlich darstellen [vgl. Chang et al. 2011, S.3998–3999; Wan 2009, S.237–238; J. J. Chen et al. 2006, S.341–343; Yu et al. 2009, S.63–64; Angehrn und Lüthi 1990, S.21–22; Zohrevandi et al. 2024, S.302]. Eine zentrale Rolle spielen dabei Feedback-Mechanismen, über die

umgesetzte Maßnahmen und Nutzerentscheidungen dokumentiert und in die Wissensbasis zurückgeführt werden [vgl. Merten 1991, S.374–376; N. Pagan et al. 2023, S.2–4]. Analog zu Human-in-the-Loop-Konzepten tragen diese Rückkopplungsschleifen dazu bei, dass Handlungsempfehlungen kontinuierlich weiterentwickelt und an veränderte Rahmenbedingungen angepasst werden [vgl. Amershi, Cakmak et al. 2014, S.107]. Gleichzeitig sind mit der Ableitung von Handlungsempfehlungen spezifische Herausforderungen verbunden. Empfehlungen beruhen häufig auf korrelativen Zusammenhängen, während ihre Umsetzung ein Verständnis kausaler Beziehungen erfordert [vgl. Fenton et al. 2020, S.1–2]. Entsprechend wird die Integration kausaler Inferenzmethoden als zentrale Voraussetzung für belastbare präskriptive Empfehlungen diskutiert [vgl. Pearl und Mackenzie 2018, S.4–7]. Darüber hinaus ist Interpretierbarkeit eine wesentliche Voraussetzung für Akzeptanz und Vertrauen auf Seiten der Entscheidungsträger [vgl. S. Liu et al. 2017, S.1319]. Schließlich erfordert die Validierung der Handlungsempfehlungen domänenspezifisches Wissen, um sicherzustellen, dass vorgeschlagene Maßnahmen nicht nur theoretisch optimal, sondern auch praktisch umsetzbar sind [vgl. Rajpathak et al. 2012, S.407–409; Z. Zhai et al. 2020, S.14].

Aus diesen Zusammenhängen leiten sich für das Referenzmodell der intelligenten Data Pipeline spezifische Anforderungen an die Überwachungsebene ab. Die **RME 5** muss eine konsistente Präsentations- und Visualisierungsschicht bereitstellen, über die Analyseergebnisse aus dem produktiven Betrieb der Machine- und Deep-Learning-Modelle nachvollziehbar, vergleichbar und handlungsleitend aufbereitet werden. Dabei ist sicherzustellen, dass die Verdichtung und visuelle Abstraktion der Modelloutputs die zugrunde liegenden kausal-prädiktiven Zusammenhänge nicht verfälscht, sondern deren Interpretation gezielt unterstützt. Zugleich erfordert die **RME 5** eine enge, explizit definierte Kopplung an die Wissensbasis (**RME 6**), sodass aktuelle Analyseergebnisse stets im Kontext historischer Ereignisse, dokumentierter Ursachen-Wirkungs-Beziehungen sowie bewährter Maßnahmen interpretiert werden können. Handlungsempfehlungen entstehen auf dieser Grundlage nicht als isolierte Reaktion auf momentane Prognosen, sondern als kontextualisierte Ableitung aus einer mit der Zeit gewachsenen Wissensgrundlage, die Erfahrungswissen systematisch verfügbar macht. Die **RME 5** übernimmt in diesem Zusammenhang die Aufgabe, diese Empfehlungen adressatengerecht aufzubereiten, zu priorisieren und so zu kommunizieren, dass sie unmittelbar in bestehende operative Entscheidungs- und Instandhaltungsprozesse integriert werden können. Darüber hinaus muss die **RME 5** so gestaltet sein, dass Rückmeldungen aus der Umsetzung von Handlungsempfehlungen strukturiert erfasst und an die Wissensbasis zurückgeführt werden können, ohne selbst Funktionen der Wissensgenerierung oder Modellanpassung zu übernehmen. Auf diese Weise entsteht eine geschlossene, aber funktional klar getrennte Rückkopplung zwischen Analyse, Wissenshaltung und operativer Entscheidungsunterstützung, die den zyklischen Charakter datengetriebener Analyseprozesse wahrt. Die **RME 5** nimmt damit im Referenzmodell eine klar abgegrenzte, zugleich jedoch zentrale Rolle ein, indem sie Analyseergebnisse operativ sichtbar macht, deren Bedeutung mithilfe expliziten Domänenwissens einordnet und sie im Sinne einer kausal informierten, wissensgestützten Entscheidungsunterstützung nutzbar macht.

5.7 RME 6 - Entscheidungsunterstützung

Die **RME 6** bildet eine zentrale Ebene innerhalb des Referenzmodells der intelligenten Data Pipeline und adressiert die systematische Nutzung von Wissen zur Unterstützung instandhaltungsbezogener Entscheidungsprozesse. Im Fokus steht dabei nicht die vollständige Automatisierung von Entscheidungen, sondern die strukturierte Bereitstellung relevanter Informationen zur Unterstützung menschlicher Entscheidungsfindung. Diese Perspektive entspricht dem grundlegenden Verständnis von Wissensmanagement, das die Identifikation, Erfassung, Speicherung, Verteilung und Nutzung organisationsrelevanter Wissensbestände umfasst, um Entscheidungsprozesse nachhaltig zu verbessern und strategischen Nutzen zu generieren [vgl. Rowley 1999, S.418-419; Despres und Chauvel 1999, S.110-111; A.F. Ragab und Arisha 2013, S.876-877; Chopra et al. 2021, S.1-2; McElroy 2010, S.9-13; zur Heiden und Kaltenpoth 2024, S.915-917].

Im Kontext der intelligenten Data Pipeline übernimmt die Wissensdatenbank die Funktion einer integrativen Wissensinstanz, in der historische Ereignisse, identifizierte Schadensbilder, Ursachenanalysen sowie dokumentierte Instandhaltungsmaßnahmen konsistent zusammengeführt werden. Die entstehende Wissensbasis bildet dabei vergangenheitsbezogene Zustände und deren Behandlung strukturiert ab und stellt diese für nachgelagerte Analyse- und Entscheidungsprozesse bereit. Diese Form der Wissensrepräsentation lässt sich konzeptionell als eine an den Grundgedanken digitaler Zwillinge angelehnte Interpretation verstehen, ohne den Anspruch zu erheben, einen vollständigen digitalen Zwilling im Sinne einer kontinuierlich synchronisierten, physikalisch-dynamischen Systemabbildung darzustellen [vgl. Qi und Tao 2018, S.3588-3589; Milanoski et al. 2023, S.1437-1438, 2023, S.1437-1438; Horn et al. 2022, S.1-2; Ebiloma et al. 2023, S.9-11]. Der Fokus liegt nicht auf der Echtzeitabbildung des gesamten Anlagenzustands, sondern auf der strukturierten Erfassung und Nutzung schadenrelevanter Zustände, deren Ursachen sowie zugehöriger Maßnahmen. Vor diesem Hintergrund kann die Wissensdatenbank als digitaler Schadenszwilling interpretiert werden, der vergangene Ereignisse und deren Lösungskontexte systematisch verfügbar macht, ohne die vollständige Funktionalität eines Digitalen Zwillings abzubilden. Die **RME 6** steht darüber hinaus in engem Zusammenhang mit wissensbasierter Instandhaltung, bei der Maschinen-, Produkt- und Prozessdaten integriert betrachtet werden, um Instandhaltungsprozesse zielgerichtet zu optimieren [vgl. Schiuma et al. 2012, S.8045-8047; Ansari 2019, S.1597-1598]. Die Qualität der daraus ableitbaren Handlungsempfehlungen ist dabei maßgeblich von der Konsistenz, Aktualität und dem Reifegrad der zugrunde liegenden Wissensbasis abhängig [vgl. Nemeth, Ansari und Sihm 2019, S.646].

Eine wesentliche Eigenschaft der Entscheidungsunterstützungsebene ist ihre enge Kopplung zur Informationsintegration. Die in **RME 3** erzeugten Labels, Metadaten und Zustandsklassifikationen dienen nicht ausschließlich dem Training datengetriebener Modelle, sondern fließen zugleich in die Wissensdatenbank ein und erweitern diese kontinuierlich. Umgekehrt können historische Ereignisse, dokumentierte Ursachen-Wirkungs-Beziehungen sowie bewährte Instandhaltungsmaßnahmen aus der Wissensdatenbank zur semantischen Absicherung und Validierung von Labeling-Prozessen herangezogen werden. Auf diese Weise entsteht eine konsistente Rückkopplung zwischen Datenannotation, Modellierung und wissensbasierter Entscheidungsunterstützung. Auf Grundlage dieser integrierten Wissens-

basis können bei neu auftretenden Anomalien oder Zustandsabweichungen vergleichbare Ereignisse aus der Vergangenheit identifiziert und kontextualisiert bereitgestellt werden. Die Entscheidungsunterstützung erfolgt dabei fallbasiert und erfahrungsorientiert, indem frühere Lösungsansätze, deren Wirksamkeit sowie begleitende Randbedingungen berücksichtigt werden. Dieses Vorgehen unterstützt das Instandhaltungspersonal bei der Bewertung möglicher Maßnahmen, ohne den Entscheidungsprozess vollständig zu automatisieren oder zu ersetzen. Vielmehr wird eine transparente und nachvollziehbare Entscheidungsgrundlage geschaffen, die datengetriebene Analyseergebnisse mit domänenspezifischem Erfahrungswissen verknüpft.

Die Entscheidungsunterstützungsebene trägt damit zur schrittweisen Entwicklung kausal-prädiktiver Entscheidungsgrundlagen bei, die perspektivisch die Ableitung präskriptiver Handlungsempfehlungen vorbereiten können. Voraussetzung hierfür ist eine kontinuierliche Rückführung neuer Erkenntnisse aus den Analyse- und Überwachungsebenen in die Wissensdatenbank, sodass das Gesamtsystem fortlaufend lernt und sich an veränderte Systemzustände anpassen kann. Im Rahmen des Referenzmodells übernimmt **RME 6** somit die Rolle einer vermittelnden Ebene zwischen datengetriebener Analyse und operativer Handlungsebene und unterstützt die langfristige Entwicklung hin zu einer präskriptiv ausgerichteten Instandhaltungsstrategie, ohne deren vollständige Automatisierung vorwegzunehmen.

5.8 RME 7 - Modellierung

Die Ebene der Modellierung (**RME 7**) überführt die in etablierten Data-Mining-Prozessmodellen wie KDD und CRISP-DM beschriebenen Phasen der Modellentwicklung, des Trainings und der Evaluation in eine funktionale Komponente der intelligenten Data Pipeline (vgl. **Kapitel 3.3.1**). Ziel dieser Ebene ist es nicht, konkrete Algorithmen oder Implementierungen festzulegen, sondern die methodischen Anforderungen und strukturellen Aufgaben zu definieren, die für eine konsistente, reproduzierbare und qualitativ abgesicherte Entwicklung von Machine- und Deep-Learning-Modellen erforderlich sind.

Im Gesamtkontext des Referenzmodells baut die **RME 7** auf den in der **RME 3** bereitgestellten, qualitätsgesicherten und vollständig gelabelten Daten auf. Diese Daten müssen den in der Vorverarbeitung definierten Kriterien entsprechen, da ihre Qualität maßgeblich die Validität, Generalisierungsfähigkeit und Robustheit der resultierenden Modelle beeinflusst. Die **RME 7** fungiert damit als methodischer Kern der Data Pipeline, in dem aus integrierten Daten belastbare Modelle abgeleitet werden, die anschließend in die Analyseebene überführt werden. In Anlehnung an *Amershi et al. (2019)* sowie an die Struktur von KDD und CRISP-DM lassen sich für die Modellierungsebene mehrere funktionale Teilschritte identifizieren, die im Referenzmodell nicht als starre Abfolge, sondern als logisch zusammenhängende Aufgabenbereiche verstanden werden.

Den Ausgangspunkt der Modellierung bildet die **Problemdefinition** in Verbindung mit der **Festlegung geeigneter Zielmetriken**. Eine präzise formulierte Aufgabenstellung ist entscheidend für die Entwicklung leistungsfähiger Modelle, da sie den Anwendungsrahmen, die relevanten Eingangsvariablen sowie die erwarteten Ausgaben eindeutig

festlegt [vgl. Acito 2023b, S.11; Passi und Barocas 2019, S.3-4]. Unklar definierte Problemstellungen führen häufig zu ungeeigneten Modellarchitekturen und inadäquaten Optimierungszielen, was sich negativ auf die Generalisierungsfähigkeit auswirkt [vgl. Domingos 2012, S.79-81]. Die Zielmetrik fungiert in diesem Zusammenhang als operationalisierte Qualitätsgröße zur objektiven Beurteilung der Modellleistung [vgl. Goodfellow et al. 2016, S.421-422]. Ihre Auswahl beeinflusst unmittelbar die Wahl der Verlustfunktion sowie die Optimierungsstrategie und stellt sicher, dass Training, Validierung und Evaluation konsistent auf dasselbe Qualitätsziel ausgerichtet sind [vgl. Botchkarev 2018, S.1-2; Goodfellow et al. 2016, S.422-424].

Darauf aufbauend umfasst **RME 7** die **systematische Datenanalyse** und das **Feature Engineering** als funktionalen Übergang zwischen integrierten Rohdaten und modellnutzbaren Eingaben [vgl. Chatfield 1986, S.5-6; Milo und Somech 2020, S.2617-2618; Martinez et al. 2017, S.3-5; Javidan et al. 2024, S.2; C. Zhang et al. 2018, S.510-511]. Die explorative Datenanalyse dient der Untersuchung statistischer Eigenschaften, Verteilungen, Korrelationen und potenzieller Ausreißer, um strukturelle Besonderheiten und Verzerrungen frühzeitig zu identifizieren [vgl. Páez und Boisjoly 2022, S.25-26; Fiser et al. 2014, S.258]. Ergänzend ermöglicht sie mithilfe geeigneter Visualisierungen die Erkennung von Mustern, Trends und Anomalien in den Daten [vgl. Peng et al. 2021, S.2273-2274; Wootton et al. 2025, S.1194-1195; Sagala und Aryatama 2022, S.581; Weihs 1993, S.306]. Das Feature Engineering zielt darauf ab, relevante Variablen gezielt auszuwählen, zu transformieren oder neu abzuleiten, um den Informationsgehalt der Eingaben zu maximieren und irrelevante oder redundante Merkmale zu eliminieren [vgl. Reid Turner et al. 1999, S.4; A. Mumuni und F. Mumuni 2025, S.118; Khalid et al. 2014; Kuhn und Johnson 2020, S.227-235]. Im Referenzmodell ergibt sich daraus die Anforderung an eine strukturierte, nachvollziehbare Ablage abgeleiteter Merkmale, um Wiederverwendbarkeit und Konsistenz über mehrere Modellierungszyklen hinweg sicherzustellen.

Ein weiterer zentraler Aufgabenbereich der **RME 7** ist die Auswahl der Lernmethode. Diese bestimmt den Hypothesenraum des Modells und damit die Art der Zusammenhänge, die aus den Daten erlernt werden können [vgl. Y. Zhang 2010, S.9-11]. Unter der Lernmethode wird hierbei die strukturelle und funktionale Organisation der Modellkomponenten verstanden, die den zulässigen Lösungsraum formal definiert [vgl. R. Wang et al. 2024, S.1-2; Marcondes et al. 2020, S.2; Blockeel 2017, S.629-631]. Im Kontext des Referenzmodells wird keine spezifische Modellfamilie festgelegt. Vielmehr ist sicherzustellen, dass unterschiedliche Verfahren des Supervised Learning unterstützt werden, deren Auswahl sich an Datenstruktur, Aufgabenstellung und Zielmetrik orientiert [vgl. Kelleher et al. 2020, S.4; Goodfellow et al. 2016, S.1-2]. Die Bereitstellung annotierter Trainings- und Testdatensätze aus der Informationsintegration bildet dabei die Voraussetzung für ein überwacht lernendes Vorgehen, bei dem Modellanpassung und Leistungsbewertung klar getrennt erfolgen.

Die **Modellkonfiguration** stellt den Übergang zwischen konzeptioneller Modellwahl und Trainingsphase dar und beeinflusst maßgeblich Lernverhalten, Modellkomplexität und Generalisierungsfähigkeit [vgl. Coe 2018, S.5739-5740; C.-O. Chen et al. 2015, S.386-387]. Dabei ist zwischen Modellparametern, die während des Trainings aus den Daten gelernt werden, und Hyperparametern zu unterscheiden, die vorab festgelegt werden und den Lern-

prozess steuern [vgl. Luo 2016, S.1-3]. Die initiale Festlegung der Hyperparameter erfolgt typischerweise auf Basis domänenspezifischen Wissens, heuristischer Richtwerte oder systematischer Suchverfahren wie Grid Search, Random Search oder Bayesian Optimization [vgl. Monica und P. Agrawal 2024, S.12-13; Andonie 2019, S.281-282; Mohammadi und Esfahanian 2025, S.6-7]. Im Referenzmodell ergibt sich daraus die Anforderung an eine automatisierbare und dokumentierte Hyperparameter-Optimierung, die in Verbindung mit Validierungsverfahren durchgeführt wird, um Überanpassung zu vermeiden [vgl. Bischl et al. 2023, S.6-7; Falkner et al. 2018, S.1437-1438; Thornton et al. 2013, S.847; Bao et al. 2021, S.1-2; Wazirali 2020, S.10863; Tetko et al. 2024, S.10].

Das **Training** bildet den zentralen Kernprozess der **RME 7**, in dem die Modellparameter iterativ an die Trainingsdaten angepasst werden [vgl. Verbraeken et al. 2021, S.5]. Methodisch erfolgt dies durch die Minimierung einer auf die Zielmetrik abgestimmten Verlustfunktion mittels geeigneter Optimierungsverfahren [vgl. Qi Wang et al. 2022, S.187-188; Chakraborty und U. Kumar 2023, S.774-778; Culotta et al. 2007, S.32-35]. Während klassische Verfahren häufig Gradientenmethoden einsetzen, bilden bei tiefen neuronalen Netzen Backpropagation-Verfahren in Kombination mit stochastischen Optimierungsalgorithmen den Standard [vgl. Qi Wang et al. 2022, S.187-189; Lillicrap et al. 2020, S.335-336; Wilson et al. 2017, S.1-5; Netrapalli 2019, S.201-202]. Die Wahl dieser Verfahren sowie ihre Parametrisierung beeinflussen Konvergenzgeschwindigkeit, Stabilität und Generalisierungsfähigkeit unmittelbar [vgl. Bian und Priyadarshi 2024, S.4212-4215]. Darüber hinaus erfordert der Trainingsprozess eine adäquate Abstimmung der Hyperparameter, da diese nicht nur die Effizienz des Optimierungsverfahrens determinieren, sondern zugleich maßgeblich zur Vermeidung von Overfitting beitragen [vgl. Ying 2019, S.1-3, 2019, S.1-3]. Im Referenzmodell ist das Training daher nicht als einzelner Rechenschritt, sondern als kontrollierter, nachvollziehbarer Prozess zu verstehen, dessen Konfiguration reproduzierbar dokumentiert werden muss.

Ergänzend ist eine **Validierung während des Trainings** vorgesehen, die der kontinuierlichen Überprüfung der Generalisierungsfähigkeit dient [vgl. Hastie et al. 2009, S.222-223; Burzykowski et al. 2023, S.295-296; Muraina 2022, S.496-497]. Durch den Einsatz disjunkter Validierungsdatensätze lassen sich Overfitting oder Underfitting frühzeitig erkennen und durch Regularisierung, adaptive Lernraten oder Early Stopping gezielt adressieren [vgl. Y. Xu und Goodacre 2018, S.249-251; Mahsereci et al. 2017, S.2; Prechelt 1998, S.761-763; Gotmare et al. 2018, S.1-2].

Die abschließende **Evaluation** erfolgt auf Basis eines unabhängigen Testdatensatzes und ermöglicht eine objektive Beurteilung der Modelleistung unter realitätsnahen Bedingungen [vgl. Genç und Tunç 2019, S.1534-1536; Riccio et al. 2020, S.5197-5198]. Die Verwendung geeigneter Evaluationsmetriken stellt sicher, dass die Einsatzfähigkeit des Modells valide beurteilt und mit alternativen Modellen verglichen werden kann [vgl. Chuah et al. 2022, S.2].

Im Referenzmodell der intelligenten Data Pipeline ist die **RME 7** konzeptionell von den übrigen Ebenen getrennt und in einer cloudnahen Umgebung verortet, während die vor- und nachgelagerten Ebenen primär in der Fabrikumgebung angesiedelt sind. Diese

Trennung reflektiert keinen konkreten Implementierungszwang, sondern folgt einer funktionalen Differenzierung, wie sie für hybride Data-Pipeline-Architekturen charakteristisch ist (vgl. **Kapitel 3.4.2**). Die Modellierung erfordert im Vergleich zum operativen Analyse- und Überwachungsbetrieb typischerweise erhöhte Rechen-, Speicher- und Skalierungsressourcen, etwa für das Training komplexer Machine- und Deep-Learning-Modelle, die Durchführung umfangreicher Hyperparameter-Optimierungen oder die Verwaltung mehrerer Modell- und Datenversionen. Eine cloudbasierte Verortung der Modellierungsebene bietet hierfür geeignete Rahmenbedingungen, ohne die Echtzeitanforderungen und Verfügbarkeitsrestriktionen der Fabrikumgebung zu belasten. Gleichzeitig bleibt **RME 7** logisch in das Gesamtsystem integriert. Die Übergabe trainierter Modelle an die **RME 4** sowie die Rückführung aktualisierter Trainingsdaten und Modellmetriken aus dem operativen Betrieb erfolgen über definierte Schnittstellen. Auf diese Weise wird ein hybrides Betriebsmodell unterstützt, bei dem rechenintensive Lernprozesse zentralisiert durchgeführt werden, während die Modellanwendung, Überwachung und Entscheidungsunterstützung prozessnah in der Produktionsumgebung verbleiben. Die Darstellung von **RME 7** in einer Cloud-Umgebung ist somit als abstrakte Referenzarchitektur zu verstehen, die die funktionale Entkopplung von Modellierung und operativem Betrieb verdeutlicht. Sie dient der Verallgemeinerbarkeit und Übertragbarkeit des Referenzmodells und ermöglicht es, unterschiedliche konkrete Umsetzungen konsistent einzuordnen.

Aus der konzeptionellen Ausgestaltung der **RME 7** ergeben sich für das Referenzmodell der intelligenten Data Pipeline Anforderungen, die sich unmittelbar aus dem Anspruch an Reproduzierbarkeit, Skalierbarkeit und methodische Konsistenz datengetriebener Modellierungsprozesse ableiten. Die Modellierungsebene ist dabei für die systematische Entwicklung, das Training, die Validierung und die Evaluation von Machine- und Deep-Learning-Modellen verantwortlich und bildet die methodische Grundlage für deren späteren operativen Einsatz. Zentrale Voraussetzung ist eine explizite und persistente Verwaltung von Problemdefinitionen, Zielmetriken und Optimierungszielen, um Modellentscheidungen, Leistungsbewertungen und Vergleichbarkeit über unterschiedliche Modellgenerationen hinweg sicherzustellen. Damit einher geht die Notwendigkeit qualitätsgesicherter, vollständig gelabelter und versionierter Datensätze, die den in den vorgelagerten Ebenen definierten Standards entsprechen und reproduzierbare Trainings- und Evaluationsprozesse ermöglichen. Ergänzend ist eine strukturierte Verwaltung abgeleiteter Merkmale erforderlich, etwa in Form eines persistenten Feature Stores, um Wiederverwendbarkeit, Nachvollziehbarkeit und Konsistenz von Merkmalsrepräsentationen über verschiedene Modelle hinweg zu gewährleisten. Darüber hinaus muss die Modellierungsebene Mechanismen zur automatisierten Hyperparameter-Optimierung, validierungsbasierten Modellbewertung sowie zur systematischen Verwaltung von Experimenten und Modellversionen bereitstellen. Die eindeutige Verknüpfung von Modellen mit ihren Trainingsdaten, Konfigurationen und Evaluationsresultaten ist dabei eine wesentliche Voraussetzung für wissenschaftliche Nachvollziehbarkeit und industrielle Einsatzfähigkeit. Das gezielte Nachtrainieren von Modellen ist konzeptionell ebenfalls der Modellierungsebene zugeordnet, auch wenn dessen Auslösung durch Erkenntnisse aus dem operativen Betrieb erfolgt. Im Referenzmodell ist **RME 7** bewusst in

einer cloudnahen Umgebung verortet, während die Analyse-, Überwachungs- und Entscheidungsunterstützungsebenen primär der Fabrikumgebung zugeordnet sind. Diese hybride Architektur stellt keine technologische Festlegung dar, sondern reflektiert eine funktionale Trennung zwischen rechenintensiven Lern- und Optimierungsprozessen und echtzeitnahen, betriebskritischen Analyse- und Entscheidungsprozessen. Entsprechend muss die Modellierungsebene definierte Schnittstellen bereitstellen, über die trainierte Modelle an die Analyseebene überführt und operative Rückmeldungen, Leistungskennzahlen oder neu gelabelte Daten zur weiteren Modellanpassung zurückgeführt werden können. Zusammenfassend stellt **RME 7** die methodische und infrastrukturelle Referenzebene für eine konsistente, skalierbare und reproduzierbare Modellentwicklung innerhalb der intelligenten Data Pipeline dar. Durch ihre abstrakte Ausgestaltung, die klare funktionale Abgrenzung zu den operativen Ebenen und die Einbettung in eine hybride Architektur erfüllt sie den Anspruch eines Referenzmodells, indem sie unterschiedliche konkrete Implementierungen erlaubt, ohne die zugrunde liegenden Prinzipien datengetriebener Modellierung festzuschreiben.

5.9 Zwischenfazit

Ein Referenzmodell zeichnet sich nach *Fettke und Loos (2004)*, *Frank (2006)*, *Cherdantseva et al. (2016)*, *Matook und Indulska (2009)* sowie *Esswein et al. (2004)* durch seine allgemeine Strukturierungs- und Orientierungsfunktion aus. Es dient als konzeptioneller Bezugsrahmen, der bewährte Vorgehensweisen, methodische Prinzipien und funktionale Zusammenhänge in abstrahierter Form beschreibt, ohne eine konkrete technische Implementierung vorzugeben. Dadurch ermöglicht ein Referenzmodell sowohl die systematische Analyse bestehender Lösungen als auch die konzeptionelle Gestaltung neuer Systeme. Zugleich fungiert es als Kommunikationsinstrument zwischen Wissenschaft und Praxis, indem komplexe Systemzusammenhänge auf ein einheitliches Begriffs- und Verständnissystem reduziert werden.

Das in diesem Kapitel entwickelte Referenzmodell der intelligenten Data Pipeline erfüllt diese Merkmale in mehrfacher Hinsicht. Es abstrahiert den Lebenszyklus datengetriebener Analysen im industriellen Umfeld von der Datenerhebung über die Vorverarbeitung, Informationsintegration und Modellierung bis hin zur Analyse, Überwachung und wissensbasierten Entscheidungsunterstützung. Dabei werden sowohl technische als auch organisatorische Aspekte berücksichtigt und über klar definierte funktionale Schnittstellen miteinander verknüpft. Das Modell beschreibt somit keine konkrete Systemarchitektur, sondern eine übertragbare Struktur, die auf unterschiedliche Produktionsdomänen, IT-Landschaften und Reifegrade anwendbar ist. Zentraler Gegenstand des Kapitels war die systematische Herleitung der Aufgaben, Funktionen und Gestaltungsanforderungen der einzelnen Ebenen des Referenzmodells. Ausgangspunkt der intelligenten Data Pipeline bildet die **RME 1**, in der die für nachgelagerte Analysen erforderlichen Rohdaten erhoben werden. Die Qualität, Vollständigkeit und zeitliche Referenzierbarkeit dieser Daten bestimmen maßgeblich die Aussagekraft aller weiteren Verarbeitungsschritte. Darauf aufbauend sorgt die **RME 2** für eine Vereinheitlichung und Bereinigung der Daten, sodass heterogene Quellen in einer konsistenten und weiterverarbeitbaren Form vorliegen. Die **RME 3** erweitert diese technische Harmonisierung um eine semantische Dimension,

indem strukturierte und unstrukturierte Daten zusammengeführt und durch Domänenwissen kontextualisiert werden. Auf dieser integrierten Informationsbasis erfolgt in der **RME 7** die eigentliche Modellbildung, in der maschinelle Lernverfahren systematisch konzipiert, trainiert, validiert und versioniert werden. Die so entwickelten Modelle werden anschließend in der **RME 4** in den operativen Einsatz innerhalb der Fabrikumgebung überführt, wo sie unter realen Bedingungen kontinuierlich mit Echtzeitdaten versorgt und stabil betrieben werden. Die durch den produktiven Modelleinsatz erzeugten Analyseergebnisse werden in der **RME 5** adressatengerecht aufbereitet, visualisiert und in Entscheidungsunterstützungskonzepte eingebettet. Dabei steht nicht die Generierung neuen Wissens, sondern die situationsbezogene Nutzung vorhandener Informationen im Vordergrund. Ergänzend übernimmt die **RME 6** die Funktion einer persistenten Wissensinstanz, in der Erfahrungs-, Ereignis- und Entscheidungswissen langfristig gespeichert, bewertet und fortlaufend erweitert wird. Durch dieses Zusammenspiel der Ebenen entsteht eine geschlossene, zyklische Systemarchitektur, die datengetriebene Analysen nicht nur ermöglicht, sondern über den gesamten Lebenszyklus hinweg stabil, nachvollziehbar und adaptiv unterstützt. Durch diese funktionale Trennung wird gewährleistet, dass Wissensgenerierung, Wissenshaltung und Wissensnutzung nicht vermischt werden. Gleichzeitig wird der zyklische Charakter datengetriebener Analysen, insbesondere die Rückkopplung zwischen Analyse, Wissensbasis und Modellierung, systematisch abgebildet. Das Referenzmodell erlaubt dabei explizit hybride Architekturen, in denen rechenintensive Modellierungs- und Trainingsprozesse in cloudnahen Umgebungen stattfinden, während operative Analyse- und Überwachungsfunktionen in der Fabrikumgebung verortet sind. Diese Trennung ist nicht als Implementierungsvorgabe, sondern als abstrahierte Gestaltungsoption im Sinne des Referenzmodellcharakters zu verstehen. Trotz der konzeptionellen Geschlossenheit des Referenzmodells ergeben sich für die praktische Umsetzung in industriellen Umgebungen verschiedene Herausforderungen. Dazu zählen insbesondere die Sicherstellung einer durchgängigen Datenqualität über Systemgrenzen hinweg, die Interoperabilität heterogener IT-Systeme, die systematische Integration von Domänenwissen sowie der Aufbau stabiler MLOps-Strukturen. Auch die Gestaltung transparenter, nutzerzentrierter Visualisierungs- und Entscheidungsunterstützungskonzepte stellt eine zentrale Herausforderung dar. Diese Aspekte betreffen jedoch nicht die Gültigkeit des Referenzmodells selbst, sondern verdeutlichen dessen Orientierungsfunktion bei der strukturierten Planung und Bewertung konkreter Umsetzungen.

Zur Sicherstellung einer konsistenten, nachvollziehbaren und theoriegeleiteten Ableitung der Systemanforderungen an das Referenzmodell werden die im Rahmen von **Kapitel 5** identifizierten Anforderungen in **Tabelle 9** in Form einer Anforderungsmatrix systematisch zusammengeführt. Die Anforderungsmatrix fasst ausschließlich jene Anforderungen zusammen, die sich aus der konzeptionellen Herleitung des Referenzmodells, den theoretischen Grundlagen sowie der strukturellen Analyse der sieben Referenzmodellebenen ergeben. Sie stellt dar, aus welchem thematischen und methodischen Kontext die jeweiligen Anforderungen abgeleitet wurden und wie sie funktional innerhalb der intelligenten Data Pipeline verortet sind. Durch diese strukturierte Zusammenführung wird die normative Zielsetzung des Referenzmodells explizit gemacht. Die Matrix beschreibt, welche Eigenschaften, Funktionen und Schnittstellen eine intelligente Data Pipeline unabhängig von

einer konkreten Implementierung erfüllen sollte. Eine Erweiterung oder Präzisierung der Anforderungen auf Basis praktischer Erkenntnisse erfolgt bewusst nicht an dieser Stelle, sondern wird im weiteren Verlauf der Arbeit im Rahmen der Demonstration und Evaluation separat betrachtet. Auf diese Weise bleibt die konzeptionelle Ableitung der Anforderungen klar von ihrer empirischen Überprüfung und möglichen Weiterentwicklung getrennt.

Tabelle 9: Anforderungsmatrix an das Referenzmodell

ID	Anforderungsdimension	Anforderung an das Referenzmodell
R1	Datenquellen	Das Referenzmodell muss die Integration strukturierter, unstrukturierter und zeitbasierter Datenquellen aus Produktionsumgebungen unterstützen.
R2	Domänenwissen	Domänenwissen ist als eigenständige, digitale und maschinenlesbare Datenquelle systematisch zu erfassen und bereitzustellen.
R3	Zeitliche Referenzierung	Alle relevanten Daten müssen über eine einheitliche zeitliche Referenz integrierbar sein, um eine konsistente Analyse über Systemgrenzen hinweg zu ermöglichen.
R4	Informationsintegration	Das Referenzmodell muss eine konsistente Integrationslogik zur Zusammenführung heterogener Daten- und Wissensquellen vorsehen.
R5	Wissensbasis	Es ist eine persistente Wissensbasis vorzusehen, in der Erfahrungs-, Ereignis- und Entscheidungswissen strukturiert abgelegt und fortlaufend erweitert werden kann.
R6	Problemdefinition	Problemstellungen, Zielgrößen und Evaluationsmetriken müssen im Modell explizit definiert und nachvollziehbar dokumentiert werden.
R7	Merkmalsmanagement	Abgeleitete Merkmale sind reproduzierbar, versionierbar und über verschiedene Modellierungszyklen hinweg wiederverwendbar bereitzustellen.
R8	Trennung Training und Betrieb	Das Referenzmodell muss eine funktionale Trennung zwischen Modellentwicklung (Training) und produktivem Modelleinsatz vorsehen.
R9	Modellbetrieb	Modelle müssen im produktiven Betrieb kontinuierlich mit Echtzeitdaten aus der Produktionsumgebung versorgt werden können.
R10	Modellüberwachung	Die Modellleistung ist im Betrieb kontinuierlich zu überwachen, um Leistungsabweichungen frühzeitig erkennen zu können.
R11	Adaptionsfähigkeit	Das Referenzmodell muss das gezielte Nachtrainieren von Modellen auf Basis neuer oder veränderter Daten unterstützen.
R12	Ergebnisvisualisierung	Analyseergebnisse sind adressatengerecht, verständlich und kontextualisiert zu visualisieren.
R13	Handlungsempfehlungen	Das Referenzmodell muss die Ableitung wissensbasierter Handlungsempfehlungen auf Basis von Analyseergebnissen und Erfahrungswissen unterstützen.
R14	Funktionale Trennung Wissen	Wissensgenerierung und -konsolidierung sind funktional von der wissensbasierten Nutzung und Entscheidungsunterstützung zu trennen.

6 Demonstration des Referenzmodells

Dieses Kapitel bildet die anwendungsbezogene Hauptphase der Arbeit und dient der Demonstration des im vorangegangenen Kapitel entwickelten Referenzmodells einer intelligenten Data Pipeline. Ziel ist es, aufzuzeigen, wie das Referenzmodell in einem realen industriellen Anwendungskontext konsistent ausgelegt und angewendet werden kann, um datengetriebene, kausal-prädiktive Instandhaltungsstrategien strukturell zu unterstützen. Im Mittelpunkt steht dabei nicht der Nachweis der Leistungsfähigkeit einzelner Verfahren, sondern die Demonstration der Anwendbarkeit, Strukturtragfähigkeit und Anschlussfähigkeit des Referenzmodells im Produktionsumfeld. Innerhalb des übergeordneten Forschungsdesigns des DSR-Ansatzes übernimmt dieses Kapitel die Rolle der Demonstrationsphase (vgl. **2.3.2**). Die entwickelten konzeptionellen Bausteine werden hierzu in einem realen Anwendungskontext eingesetzt und entlang konkreter Fallstudien ausgestaltet, um ihre Eignung zur strukturierten Abbildung datenanalytischer Instandhaltungsansätze zu untersuchen und kritisch zu reflektieren.

Der Aufbau des Kapitels folgt einer schrittweisen Annäherung an den Anwendungskontext. In **Kapitel 6.1** wird zunächst die Strukturierung der betrachteten Fallstudien erläutert. Darauf aufbauend erfolgt in **Kapitel 6.2** eine systematische Einordnung der zugrunde liegenden Produktionsdomäne. **Kapitel 6.3** beschreibt anschließend die Auslegung und Einbettung des Referenzmodells in die bestehende Produktionsumgebung. Zur Illustration der operativen Anwendung werden in **Kapitel 6.4** ausgewählte datenanalytische Anwendungsfälle herangezogen, welche die Nutzung des Referenzmodells auf der Mikroebene verdeutlichen. Ergänzend wird in **Kapitel 6.5** ein systematischer Abgleich zwischen den in **Kapitel 5** abgeleiteten Anforderungen und der exemplarischen Anwendung des Referenzmodells vorgenommen, um transparent darzustellen, in welchem Umfang und auf welche Weise die definierten Anforderungen durch die Umsetzung adressiert werden, ohne eine abschließende Bewertung vorwegzunehmen.

6.1 Strukturierung der Fallstudien

Die Strukturierung und Ausgestaltung der Fallstudien in diesem Kapitel basiert auf der in **Kapitel 2.5.2** beschriebenen methodischen Vorgehensweise und dient der anwendungsbezogenen Auslegung des in **Kapitel 5** entwickelten Referenzmodells einer intelligenten Data Pipeline. Ziel der Fallstudien ist es, die Anwendbarkeit und strukturelle Tragfähigkeit des Referenzmodells in einem realen industriellen Kontext aufzuzeigen und dessen Fähigkeit zur systematischen Abbildung datengetriebener Instandhaltungsstrategien zu untersuchen. Dabei steht nicht die Bewertung einzelner Algorithmen oder konkreter Lösungsausprägungen im Vordergrund, sondern die konsistente Anwendung des Referenzmodells über unterschiedliche Ebenen und Anwendungsfälle hinweg.

Ausgangspunkt der Untersuchung bildet die Makroebene, auf der das in **Kapitel 5** entwickelte Referenzmodell einer intelligenten Data Pipeline zur Umsetzung einer kausal-prädiktiven Instandhaltungsstrategie angewendet wird. Das Referenzmodell stellt das zentrale Artefakt der vorliegenden Arbeit dar und integriert wesentliche Bausteine wie Datenaufnahme, Datenintegration, Datenverarbeitung, Modellierung, Analyse sowie die An-

bindung der Analyseergebnisse. Die so bereitgestellte Daten- und Analysebasis schafft die Voraussetzungen für eine weiterführende präskriptive Entscheidungsunterstützung, ohne diese selbst explizit zu implementieren. Als übergeordneter Fall umfasst die Makroebene damit nicht nur die technische Architektur der Data Pipeline, sondern auch deren organisatorische und prozessuale Einbettung in die Produktionsumgebung. Als Anwendungskontext wird das Presswerk am Hauptsitz eines Automobilherstellers herangezogen. Auf dieser Ebene wird untersucht, inwieweit sich das Referenzmodell in einer realen industriellen Umgebung konsistent auslegen lässt und welche strukturellen, organisatorischen und datenbezogenen Rahmenbedingungen hierfür erforderlich sind.

Von der Makroperspektive ausgehend erfolgt auf der Mikroebene eine differenzierte Betrachtung konkreter Anwendungsfälle, die der Auslegung ausgewählter Komponenten des Referenzmodells dienen. Hierzu werden drei Data-Mining-Anwendungsgebiete als eigenständige Fälle definiert, die jeweils unterschiedliche funktionale Bausteine der intelligenten Data Pipeline adressieren und deren Anwendbarkeit im Kontext kausal-prädiktiver Instandhaltungsstrategien aufzeigen. Ziel der Mikro-Fälle ist es nicht, isolierte Verfahren zu bewerten, sondern die konsistente Einbettung datenanalytischer Ansätze in die Struktur des Referenzmodells zu untersuchen. Die Auswahl der betrachteten Fälle orientiert sich an der in **Kapitel 2** beschriebenen methodischen Vorgehensweise sowie an anerkannten Gütekriterien der Fallstudienforschung und berücksichtigt zugleich die Datenverfügbarkeit innerhalb der betrachteten Domäne. Ausgangspunkt bildet die Identifikation potenziell verfügbarer Datenquellen im Presswerk, die im Hinblick auf ihre Eignung zur Abbildung kausal-prädiktiver Zusammenhänge bewertet werden (vgl. **Kapitel 6.2.4**). Berücksichtigt werden insbesondere kontinuierlich erhobene Sensordaten sowie ergänzende technische Dokumentationen und Prozessbeschreibungen. Darüber hinaus wird bei der Fallauswahl die strukturelle Übertragbarkeit der gewonnenen Erkenntnisse berücksichtigt. Die untersuchten Anwendungsfälle sind so gewählt, dass sie nicht ausschließlich für das betrachtete Presswerk relevant sind, sondern sich hinsichtlich der zugrunde liegenden System- und Prozesslogik auf vergleichbare Produktionsumgebungen übertragen lassen. Auf diese Weise wird sichergestellt, dass die Mikro-Fälle sowohl den wissenschaftlichen Anforderungen an eine strukturierte Analyse als auch den praktischen Randbedingungen industrieller Produktionssysteme gerecht werden. Der erste Fall umfasst das Ziehkissen einer Umformanlage. Ein Ziehkissen, auch *drawing cushion* genannt, ist in einer Umform- oder Tiefziehpressanlage eine kontrollierbare Kraftquelle, die dazu genutzt wird, über einen Blechhalter einen geregelten Gegendruck auf das Blechteil auszuüben [vgl. Altan und Penter 2010, S.2-3]. Ziel ist, das Werkstück während des Ziehvorgangs gegen unerwünschten Materialnachschieb oder Faltenbildung zu stabilisieren und eine kontrollierte Materialverteilung zu ermöglichen [vgl. Großmann et al. 2013, S.1-3]. Der zweite Fall betrachtet den Zahnstangenantrieb, der in einer Transferpresse genutzt wird, um Werkstücke von Pressenstufe zu Pressenstufe zu bewegen, indem sie rotatorische Bewegung des Servomotors in die erforderliche lineare Bewegung der Transferachsen umwandeln [vgl. Birkert et al. 2013, S.321-322; Sawicki 2021, S.2-3]. Über den Einsatz an Transferpressen hinaus kommen Zahnstangenantriebe in Werkzeugmaschinen wie Portalfräsanlagen, in Automatisierungs- und Transfersystemen der Serienproduktion, in der Verpackungs- und Lebensmittelindustrie für Vorschub- und

Hubbewegungen, in Schneid- und Schweißanlagen der Blechbearbeitung, in Schwerindustrieanlagen wie Walzwerken und Kraftwerken sowie in der Bau- und Fördertechnik etwa bei Aufzügen und Hubwerken zum Einsatz [vgl. Steinle et al. 2022, S.453-455; Verl und Engelberth 2018, S.369-370; Pawar et al. 2017, S.30-31; Sawicki 2021, S.2; So 2019, S.3-4]. Der dritte Fall umfasst den Druckluftgreifer in einer Umformanlage. Dieser ist ein pneumatischer Greifer, der Bauteile vor, zwischen oder nach Umformoperationen greift, positioniert, übergibt oder entnimmt, wobei die Erzeugung der Greifkraft durch Luftdruck erfolgt, der über Steuer- und Regelventile dosiert wird [vgl. Hoffmann und Kohnhäuser 2002, S.27-28; Mykhailyshyn et al. 2022, S.204-205]. Pneumatische Druckluftgreifer finden neben der Umformtechnik insbesondere in der Montage von Bauteilen, der Elektronikindustrie bei der präzisen Positionierung empfindlicher Komponenten, der Logistik und Verpackungstechnik sowie in der Soft Robotics für flexible Handhabungsaufgaben Anwendung [vgl. Song et al. 2021, S.1-3; Mykhailyshyn et al. 2022, S.202-203; H. Pham und Q.-C. Pham 2019, S.3045-3046; Um et al. 2024, S.87-88]. Jeder der Mikro-Fälle ist eigenständig ausgestaltet, folgt jedoch einer einheitlichen Forschungslogik und ist konsistent in das übergeordnete Referenzmodell eingebettet.

Folglich ergibt sich für die vorliegende Arbeit das in **Abbildung 14** dargestellte Fallstudiendesign. Dieses zweistufige Vorgehen, mit einem Makro-Fall und drei Mikro-Fällen, entspricht methodisch einer eingebetteten Multifallstudie. Auf der Makroebene wird die Übertragbarkeit des Referenzmodells als Ganzes geprüft, während auf der Mikroebene die Praxistauglichkeit spezifischer Data-Mining-Verfahren evaluiert wird. Durch die Kombination einer top-down orientierten Gesamtbetrachtung mit einer bottom-up orientierten Detailanalyse werden sowohl die interne Validität (durch die Betrachtung kausaler Mechanismen innerhalb der intelligenten Data Pipeline) als auch die externe Validität (durch die Replikationslogik über mehrere Fälle hinweg) gestärkt. Somit trägt das gewählte Design entscheidend dazu bei, die theoretische Fundierung des Referenzmodells empirisch zu überprüfen und seine praktische Anwendbarkeit in industriellen Kontexten nachzuweisen.




Abbildung 14: Fallstudiendesign der vorliegenden Arbeit

6.2 Systematische Bestandsaufnahme der Produktionsdomäne

Im Rahmen der vorliegenden Arbeit erfolgt eine systematische Bestandsaufnahme der betrachteten Produktionsdomäne, um ein fundiertes Verständnis der bestehenden organisatorischen, technischen und informationstechnischen Strukturen zu gewinnen. Ziel dieser Analyse ist es, die Ausgangssituation der Produktionsdomäne umfassend zu erfassen und die relevanten Rahmenbedingungen für die nachfolgende Evaluation des Artefakts zu identifizieren. Die Bestandsaufnahme orientiert sich methodisch an den Grundsätzen empirischer Forschung und umfasst die Erhebung und Analyse von Prozessen, Systemen und Dokumentationspraktiken innerhalb der Produktionsumgebung (vgl. **Kapitel 2.5.2**). Eine zentrale Quelle der Evidenz wird hierbei durch die **direkte Beobachtung** gewährleistet, die als eine der sechs wesentlichen Formen empirischer Datenerhebung beschreibt. Da der Forschende im Presswerk tätig ist und damit unmittelbaren Zugang zu den betrieblichen Abläufen, Systemen und Instandhaltungsstrukturen besitzt, können Beobachtungen und Analysen unmittelbar aus der realen Domänenpraxis abgeleitet werden. Dies ermöglicht eine tiefgehende und kontextspezifische Erfassung der empirischen Gegebenheiten, die über eine rein dokumentenbasierte Analyse hinausgeht. Ergänzend wird die Untersuchung durch die erarbeiteten wissenschaftlichen Arbeiten sowie Patente, die während der Forschungszeit entstanden sind, gestützt. Diese liefern zusätzliche Einblicke in den technologischen Entwicklungsstand sowie in relevante Forschungsergebnisse und Innovationen. Aufgeführt sind die Dokumente in **Anhang 22** und dienen als weitere Evidenzquelle im Sinne der geforderten methodischen Triangulation. In Anbetracht der Bestandsaufnahme wird in **Kapitel 6.2.1** die betrachtete Produktionsdomäne näher erläutert. Darauf folgend werden insbesondere die Instandhaltungsprozesse in **Kapitel 6.2.2**, die zugrunde liegende technische Infrastruktur in **Kapitel 6.2.3**, die Datenerfassung mittels Sensorik in **Kapitel 6.2.4** sowie die eingesetzten Anlagenerfassungs- und Dokumentationssysteme in **Kapitel 6.2.5** untersucht. Abschließend werden in **Kapitel 6.2.6** die wesentlichen Inhalte der systematischen Bestandsaufnahme zusammengefasst und reflektiert. Diese strukturierte Herangehensweise ermöglicht es, bestehende Schwachstellen, Schnittstellen und Potenziale innerhalb der Produktionsdomäne systematisch zu identifizieren und bildet somit die empirische Grundlage für die nachfolgenden Evaluationsschritte.

6.2.1 Das Presswerk als betrachtete Produktionsdomäne

Die Produktionsdomäne, auf die sich die vorliegende Arbeit bezieht, ist das Presswerk am Hauptsitz der Volkswagen AG. Presswerke bilden innerhalb der automobilen Wertschöpfungskette eine zentrale Stufe der Karosserieteilfertigung. Sie dienen der Umformung von metallischen Flachhalbzeugen zu dreidimensionalen Bauteilen und sind damit ein wesentlicher Teil der Wertschöpfungskette des Automobilbaus [vgl. Hosford und Caddell 2012, S.255-257]. Der Gesamtprozess lässt sich grundsätzlich in die Platinenfertigung und den Umformprozess in der Pressenlinie unterteilen, deren Fertigungsverfahren in der *DIN8580:2022-12* definiert sind. Im ersten Schritt werden angelieferte Metallcoils zu ebenen Zuschnitten, auch Platinen genannt, verarbeitet. In der anschließenden Umformung werden die Platinen in mehrstufigen Presslinien zu geometrisch komplexen Karosserieteilen transformiert. Eine moderne Presslinie umfasst dabei typischerweise mehrere aufeinander-

folgende Stufen, deren Werkzeugsätze je nach Bauteil variiert werden [vgl. Merklein et al. 2012, S.730-731].

Die Architektur einer Transferpressenlinie, die als Grundlage für die Fallstudien herangezogen wird, ist in der **Abbildung 15** vereinfacht dargestellt. Im ersten Abschnitt erfolgt die Materialzuführung, bei der pneumatisch oder elektrisch betriebene Handhabungssysteme die Platinen der ersten Umformstufe zuführen [vgl. Nunes et al. 2022, S.2045-2047]. Der mittlere Bereich umfasst die eigentliche Umformung, die überwiegend durch Tiefziehen und Streckziehen realisiert wird [vgl. Schuler GmbH 1998, S.5-16]. Dabei kommen hochdynamische Presssysteme zum Einsatz, die Umformkräfte im Bereich mehrerer tausend Tonnen erzeugen. Nachgelagerte Stufen übernehmen Beschnitt-, Stanz- und Umformoperationen, um die endgültige Bauteilgeometrie zu erzielen [vgl. Jin und J. Shi 2005, S.231-232]. Das entstehende Restmaterial wird automatisiert über Fördereinrichtungen zu nachgeschalteten Schrottpressen transportiert. Der Transport der Werkstücke zwischen den einzelnen Umformstationen erfolgt über synchronisierte Transfersysteme, die eine präzise Positionierung und zeitlich abgestimmte Taktung gewährleisten [vgl. Soda 1994, S.403-406]. Am Ende der Linie befindet sich die Entnahme- und Stapelstation, in der die fertigen Karosserieteile abgelegt und für den innerbetrieblichen Transport vorbereitet werden. Folglich ist das Presswerk als Gesamtsystem durch eine hohe technologische Komplexität gekennzeichnet [vgl. Jeswiet et al. 2008, S.4-6]. Mechanische, hydraulische, pneumatische, sensorische und informationstechnische Subsysteme wirken in eng aufeinander abgestimmten Abläufen zusammen [vgl. Jankovič et al. 2021, S.411-412]. Die Fallstudien im Presswerk stellen für sich betrachtet unabhängige technologische Einheiten dar, die gemäß des ersten Schrittes der in **Kapitel 3.3.1** vorgestellten Data Mining Methoden (KDD, CRISP-DM), in der jeweiligen Fallstudie detailliert erörtert werden.




Abbildung 15: Schaubild Transferpressenlinie

6.2.2 Instandhaltungsorganisation

Das Presswerk am Hauptsitz der Volkswagen AG gilt als eines der größten seiner Art. Aufgrund seiner Dimensionen und der Vielzahl eingesetzter Umformanlagen stellt es eine hochkomplexe Produktionsumgebung dar, in der Komponenten aus zahlreichen technischen Disziplinen - mechanisch, elektrisch, hydraulisch, pneumatisch, logistisch, sensorisch und informationstechnisch – ineinandergreifen. Die Anlagen werden im kontinuierlichen Dreischicht-Betrieb betrieben, wodurch eine hohe technische Verfügbarkeit zwingend erforderlich ist. Diese technologische Vielfalt und die damit verbundenen Verfügbarkeitsanforderungen bedingen eine umfangreiche Instandhaltungsorganisation innerhalb des Presswerks. Die Instandhaltungsorganisation ist in mehrere spezialisierte Einheiten gegliedert, deren Expertise sich zusammengefasst in die Themengebiete Mechanik, Elektrik, IT, Condition Monitoring und Werkzeuge gliedern lassen.

Übergeordnet übernimmt das **technische Büro** eine übergeordnete Leitungs- und Steuerungsfunktion und ist für die Planung, Koordination und Dokumentation geplanter sowie ungeplanter Instandhaltungsaufträge zuständig. Dazu zählen sowohl Routinewartungen als auch Retrofit-Maßnahmen und die Integration neuer Anlagen in den Produktionsbetrieb. Das Team agiert dabei als Schnittstelle zwischen Anlagenbetrieb, Planung und der ausführenden Instandhaltung.

Die **mechanische** und **elektrische Werkstatt** bilden gemeinsam die operative Ausführungsebene der Instandhaltung. Während die übergeordneten technischen Büros und Analyseteams für Planung, Koordination und Ursachenanalysen verantwortlich sind, liegt in diesen Werkstätten der Fokus auf der praktischen Umsetzung geplanter und ungeplanter Instandhaltungsmaßnahmen. Die Teams übernehmen Reparaturen, Austausch- und Justierarbeiten an mechanischen, hydraulischen und elektrischen Komponenten der Umformanlagen und gewährleisten so die technische Betriebsbereitschaft im laufenden Dreischicht-Betrieb. Im Rahmen geplanter Instandhaltungen führen sie präventive Wartungen, Schmier- und Inspektionsarbeiten durch, während bei ungeplanten Stillständen kurzfristige Fehlersuchen und Störungsbeseitigungen im Vordergrund stehen (vgl. **Kapitel 3.1**). Dabei erfolgt eine enge Abstimmung zwischen mechanischer und elektrischer Werkstatt, um mechatronische Schnittstellen, wie beispielsweise zwischen Antriebs-, Steuerungs- und Sensorsystemen, effizient zu bearbeiten. Durch diese interdisziplinäre Zusammenarbeit wird sichergestellt, dass sowohl mechanische als auch elektrische Ursachen für Anlagenstörungen schnell identifiziert und behoben werden können. Darüber hinaus unterstützen die Werkstattteams die Umsetzung von Retrofit-Maßnahmen und den Austausch verschlissener Baugruppen. Sie bilden somit die Schnittstelle zwischen der operativen Instandsetzung und der technischen Weiterentwicklung der Anlagen. Ihre Arbeit trägt entscheidend dazu bei, ungeplante Stillstandszeiten zu minimieren, die Anlagenverfügbarkeit zu sichern und die OEE auf einem hohen Niveau zu halten.

Die **Werkzeuginstandhaltung** ist für die Wartung, Instandsetzung und Aufbereitung der in den Pressen verwendeten Werkzeuge zuständig. Aufgrund der hohen Präzisionsanforderungen an Karosseriebauteile und der extremen Belastungen im Umformprozess ist dieser Bereich von besonderer Bedeutung für die Produktqualität. Das Team übernimmt die Reinigung, Vermessung und Wiederherstellung der Werkzeugkomponenten und trägt damit wesentlich zur Prozessstabilität und Teilequalität bei. Eng abgestimmte Abläufe mit der mechanischen und elektrischen Instandhaltung sind erforderlich, um Werkzeugwechsel, Prüfungen und Freigaben zeitlich und organisatorisch in die Produktionsplanung zu integrieren.

Das **Prozessanalyse-Team** und das **Elektroanalyse-Team** bilden gemeinsam die analytische Kompetenzebene der Instandhaltung. Beide Einheiten verfolgen das Ziel, Störungen, Qualitätsabweichungen und Anlagenstillstände systematisch zu untersuchen, um deren Ursachen zu identifizieren und nachhaltige Abstellmaßnahmen abzuleiten. Während das Prozessanalyse-Team vorrangig auf die ganzheitliche Betrachtung mechanischer, hydraulischer und prozessbedingter Ursachen fokussiert ist, richtet sich das Elektroanalyse-Team auf die Diagnose komplexer elektrischer, elektronischer und steuerungstechnischer Fehler. In enger Zusammenarbeit nutzen beide Teams moderne Diagnosesysteme, Prozess-

daten und Sensordaten, um Abweichungen im Produktionsablauf frühzeitig zu erkennen und Korrelationen zwischen mechanischen und elektrischen Einflussgrößen aufzudecken. Ihre Arbeit umfasst sowohl kurzfristige Fehleranalysen im Störfall als auch langfristige Trenduntersuchungen zur Verbesserung der Prozessstabilität. Darüber hinaus sind beide Teams in die technische Weiterentwicklung und Optimierung der Anlagen eingebunden, etwa durch die Validierung neuer Steuerungs- und Überwachungssysteme oder durch die Analyse von Retrofit-Maßnahmen.

Das **Condition Monitoring-Team** hat eine zentrale Rolle bei der Überwachung und Bewertung des technischen Anlagenzustands. Es nutzt sensorbasierte Erfassungssysteme, die in **Kapitel 6.2.3** zu technischen Infrastruktur näher betrachtet werden, zur kontinuierlichen Überwachung mechanischer, elektrischer und prozessbezogener Parameter. Ziel ist es, Abweichungen frühzeitig zu erkennen, um Ausfälle präventiv zu vermeiden. Darüber hinaus befasst sich das Team mit der Entwicklung und Implementierung datengetriebener Zustandsüberwachungssysteme und arbeitet im Rahmen von internen Data Science-Vorhaben eng mit den jeweiligen IT-Bereichen zusammen. Die erfassten Daten dienen nicht nur der kurzfristigen Fehlererkennung, sondern bilden auch eine Grundlage für langfristige Trendanalysen und für die potenzielle Entwicklung entlang der Evolution der Instandhaltungsstrategien (vgl. **Kapitel 3.1.3**).

Das **IT-Team** übernimmt innerhalb der Instandhaltungsorganisation die Verantwortung für den reibungslosen Betrieb und die kontinuierliche Verfügbarkeit der IT-Infrastruktur, deren Aufbau und Funktionsweise in **Kapitel 6.2.3** ausführlich beschrieben werden. Es stellt sicher, dass alle systemtechnischen Komponenten, Server und Netzwerke, die den Instandhaltungs- und Produktionsbetrieb unterstützen, stabil und sicher funktionieren. Darüber hinaus liegt in diesem Team die Zuständigkeit für die Betriebsdatenerfassung, einschließlich der Erfassung, Speicherung und Verarbeitung von Prozess-, Maschinen- und Zustandsdaten. Damit gewährleistet das Team die Datenkonsistenz und -verfügbarkeit über alle Ebenen der Produktions- und Instandhaltungssysteme hinweg. Zudem verantwortet das IT-Team die Pflege und Überwachung der Schnittstellen zwischen den Fertigungsanlagen, deren Steuerungssystemen sowie den übergeordneten Leitsystemen. Es trägt somit maßgeblich dazu bei, dass Instandhaltungsmaßnahmen datenbasiert geplant, Rückmeldungen automatisiert erfasst und technische Zustandsinformationen in die kontinuierliche Prozessoptimierung einfließen können.

Durch diese mehrstufige Struktur stellt die Instandhaltung sicher, dass sämtliche technischen und organisatorischen Aspekte der Anlagenbetreuung abgedeckt sind. Die Spezialisierung der Teams ermöglicht eine hohe fachliche Tiefe, gleichzeitig erfordert die Vielzahl an Schnittstellen eine effiziente Abstimmung und Koordination. Diese Komplexität verdeutlicht, dass die Instandhaltungsorganisation im Presswerk nicht nur eine reaktive Unterstützungsfunktion einnimmt, sondern als integraler Bestandteil der Produktionssteuerung agiert. Aus der beschriebenen Instandhaltungsorganisation lassen sich zusammenfassend die Instandhaltungsmaßnahmen im Presswerk situativ in **geplant** und **ungeplant** kategorisieren. Diese Unterscheidung ist zentral, da sie den Ressourceneinsatz, die Ablaufsteuerung sowie die Auswirkung auf die Anlagenverfügbarkeit und die OEE bestimmt.

Die **geplanten Instandhaltungsmaßnahmen**, die als Arbeitsablaufdiagramm in **Abbildung 16** dargestellt sind, werden auf Basis definierter Wartungszyklen, Herstellervorgaben oder zustandsbasierter Kennwerte initiiert. Ihre Durchführung dient der präventiven Sicherstellung der Funktionsfähigkeit der Umformanlagen und erfolgt in enger Abstimmung zwischen dem technischen Büro, den ausführenden Werkstattteams sowie der Produktionsplanung. Das technische Büro übernimmt hierbei die Koordination der Maßnahmen, die Erstellung und Freigabe der Arbeitsaufträge sowie die Abstimmung der zeitlichen Einplanung mit den Produktionsverantwortlichen. Zudem werden notwendige Ersatzteile, Betriebsmittel und Werkzeuge bereitgestellt. Die operative Umsetzung erfolgt durch die mechanischen und elektrischen Werkstätten, die die Arbeiten nach standardisierten Prüfvorgaben durchführen. Nach Abschluss der Tätigkeiten wird der Anlagenzustand kontrolliert, der Arbeitsauftrag geschlossen und der Vorgang im digitalen Instandhaltungssystem dokumentiert. Diese strukturierte Vorgehensweise ermöglicht eine gezielte Ressourcenplanung, reduziert ungeplante Stillstände und trägt zur Erhöhung der Anlagenverfügbarkeit bei. Erkenntnisse aus wiederkehrenden Wartungsmaßnahmen fließen zudem in die Anpassung der Wartungszyklen ein, wodurch die Maßnahmen schrittweise optimiert werden.




Abbildung 16: Arbeitsablaufdiagramm geplante Instandhaltung

Die **ungeplanten Instandhaltungsmaßnahmen**, wie sie als Arbeitsablaufdiagramm in **Abbildung 17** zu sehen sind, werden reaktiv infolge eines unerwarteten Anlagenstillstands oder Funktionsausfalls eingeleitet. Sie zeichnen sich durch hohe zeitliche Dringlichkeit und direkte Auswirkungen auf den Produktionsbetrieb aus. Tritt eine Störung auf, wird diese zunächst durch das Anlagenbedienpersonal erkannt und im digitalen Instandhaltungssystem als Störmeldung erfasst. Anschließend erfolgt eine erste Zustandsbewertung

durch den Anlagenführer, um zu prüfen, ob eine sofortige Behebung möglich ist oder ob Instandhaltungspersonal angefordert werden muss. Bei komplexeren Störungen werden die entsprechenden Fachteams alarmiert. In der Regel arbeiten hierbei das mechanische und das elektrische Team parallel, um mechatronische Fehlerbilder ganzheitlich zu analysieren und schnellstmöglich abzustellen. Nach Eintreffen an der Anlage wird eine Ursachenanalyse durchgeführt, wobei technische und sensorische Diagnosesysteme genutzt werden, um den Fehler präzise zu lokalisieren. Ist eine kurzfristige Behelfsreparatur möglich, wird diese unmittelbar durchgeführt, um den Produktionsbetrieb temporär aufrechtzuerhalten. In Fällen, in denen eine sofortige Instandsetzung erforderlich ist, erfolgt eine Eskalation über die interne Meldekette bis hin zur Produktionsleitung oder zu externen Systemlieferanten. Nach der Wiederinbetriebnahme wird der Vorgang im digitalen Instandhaltungssystem dokumentiert, analysiert und bei Bedarf in die präventive Maßnahmenplanung überführt.




Abbildung 17: Arbeitsablaufdiagramm ungeplante Instandhaltung

Sowohl geplante als auch ungeplante Instandhaltungsmaßnahmen werden vollständig im digitalen Instandhaltungssystem, dessen Funktionalitäten in **Kapitel 6.2.3** detailliert betrachtet werden, dokumentiert. Dieses System unterstützt die Erfassung von Störgründen, Zeitaufwänden, beteiligten Teams und Ersatzteilen und dient zugleich als Grundlage für Kennzahlenanalysen, etwa zur Berechnung der Stillstandszeiten und zur Bewertung der OEE. Darüber hinaus werden die gewonnenen Erkenntnisse in den täglichen Schichtübergaben kommuniziert, um Wissenstransfer und kontinuierliche Verbesserung sicherzustellen.

6.2.3 Technische Infrastruktur

Die technische Infrastruktur bildet das Fundament der betrieblichen Leistungsfähigkeit und fungiert als zentrale Voraussetzung für sämtliche produktions- und instandhaltungsrelevanten Prozesse. Sie umfasst die Gesamtheit der physischen und digitalen Systeme, über die der Datenaustausch, die Prozesssteuerung sowie die Kommunikation zwischen Anlagen,

Sensorik und IT-Systemen gewährleistet werden. Im Rahmen dieser Arbeit stellt die detaillierte Ist-Aufnahme der bestehenden technischen Infrastruktur einen essenziellen Schritt dar, um ein umfassendes Verständnis der aktuellen Systemarchitektur, der eingesetzten Technologien sowie der vorhandenen Schnittstellen zu gewinnen. Diese Erhebung dient nicht allein der Bestandsdokumentation, sondern bildet die analytische Grundlage, um die Integration des in dem **Kapitel 5** entwickelten Referenzmodells der intelligenten Data Pipeline in die bestehende Infrastruktur bewerten zu können. Nur durch die genaue Kenntnis der vorhandenen technischen Gegebenheiten lässt sich beurteilen, inwieweit bestehende Systeme erweiterungsfähig sind, welche Anpassungen erforderlich werden und an welchen Punkten eine nahtlose Einbindung datengetriebener Prozesse möglich ist. Darüber hinaus ermöglicht die Ist-Aufnahme eine systematische Erfassung der aktuell erhobenen Mess- und Betriebsdaten sowie Anlagendokumentationen, die in den unterschiedlichen Ebenen der Anlagensteuerung, Prozessüberwachung und Betriebsdatenerfassung generiert werden. Diese Datengrundlage ist von zentraler Bedeutung, um die Eignung und Verfügbarkeit der Informationen für weiterführende Data-Mining-Anwendungen zu bewerten. Somit schafft die Analyse der technischen Infrastruktur die notwendige Transparenz, um den Übergang von einer konventionellen, reaktiv geprägten Datenlandschaft hin zu einer integrierten, intelligenten Datenarchitektur gezielt zu gestalten und zu integrieren.

Im Rahmen der technischen Gesamtarchitektur nimmt die **IT-Infrastruktur** eine zentrale Rolle ein, da sie die Basis für die Erfassung, Verarbeitung und Bereitstellung betrieblicher Daten bildet. Sie umfasst sämtliche Hard- und Softwarekomponenten, Netzwerksysteme sowie Daten- und Kommunikationsschnittstellen, die den Informationsfluss zwischen den Anlagenebenen, der Betriebsdatenerfassung und den übergeordneten Managementsystemen sicherstellen. Die Analyse der bestehenden IT-Infrastruktur, die in **Abbildung 18** dargestellt ist, ist entscheidend, um die strukturellen und technologischen Voraussetzungen für datengetriebene Anwendungen zu bewerten. Sie zeigt auf, in welchem Maße aktuelle Systeme Anforderungen an Datenverfügbarkeit, -qualität und -integrität erfüllen und wo technische Anpassungen notwendig sind, um eine konsistente und skalierbare Data Pipeline zu schaffen. Im Kontext dieser Arbeit dient der Überblick dazu, jene Komponenten und Kommunikationspfade zu identifizieren, die für die Integration des entwickelten Referenzmodells der intelligenten Data Pipeline relevant sind. Dadurch wird eine fundierte Basis geschaffen, um die Einbindung der Pipeline in bestehende IT-Strukturen gezielt zu planen und die Nutzung vorhandener Mess- und Betriebsdaten für Data-Mining- und Analyseanwendungen sicherzustellen.

Die bestehende IT-Architektur orientiert sich einerseits an den zentralen IT-Vorgaben des Konzerns und andererseits an den spezifischen funktionalen und sicherheitstechnischen Anforderungen des Presswerks. Die Infrastruktur hat sich über die Jahre sukzessive weiterentwickelt und bildet heute ein mehrstufiges, nach sicherheitsrelevanten Kriterien segmentiertes Systemumfeld. Grundlage dieser Struktur ist ein Sicherheits- und Zonenmodell, das eine klare Trennung zwischen Produktions- und Office-Netzwerk sowie eine kontrollierte Kommunikation zwischen den einzelnen Ebenen gewährleistet (vgl. **Abbildung 18**). Die Architektur gliedert sich in **fünf Zonen**, die jeweils spezifische Aufgaben und Schutzmechanismen abbilden. Die **Zone 4** umfasst die Maschinen- und Anlagennetze. Hier sind

die vollständig vernetzte Automatisierungstechnik, speicherprogrammierbare Steuerungen (SPS), Antriebsregler, Sensoren, Aktoren, Roboter, Prozessleitsysteme, Prüfstationen sowie Programmiergeräte integriert. Diese Ebene stellt das Kernstück der operativen Produktion dar und ist unmittelbar mit der Datenerfassung und Prozesssteuerung verbunden. Die **Zone 3** fungiert als demilitarisierte Zone (DMZ) und trennt das operative Produktionsnetz von übergeordneten IT-Ebenen. In dieser Zone werden Systeme wie Condition-Monitoring-Plattformen, OPC UA-Server oder Anlagencluster mit eigenständigen Segmenten betrieben. Durch das unterbrochene Routing wird ein direkter Zugriff aus höheren Zonen verhindert, wodurch Manipulations- oder Schadensrisiken reduziert werden. In der **Zone 2** befinden sich die übergeordneten Produktionsnetze und IT-Infrastrukturen, die zentrale Dienste und Managementfunktionen bereitstellen. Dazu zählen Produktionsleitsysteme (MES), Betriebsdatenerfassungssysteme (BDE), Server- und Speicherarchitekturen, Sicherheits- und Managementsysteme sowie Visualisierungsterminals. Diese Zone übernimmt die Aggregation und Weiterverarbeitung der aus den Maschinen- und Prozessnetzwerken gewonnenen Daten und stellt somit die Verbindung zur IT-Ebene her. Die **Zone 1** bildet eine weitere DMZ, in der Systeme mit kontrolliertem externem Zugriff, wie Webserver, Proxys oder Fernwartungslösungen, betrieben werden. Eine logische Erweiterung dieser Zone stellt die **Zone 1a** dar, die als geplante Umgebung für Edge Devices, erweiterte Fernwartungssysteme und Daten-Gateways vorgesehen ist. Diese Zone dient insbesondere der sicheren Netzwerkadressübersetzung zwischen dem Produktionsnetz und dem Office-Netz und ermöglicht perspektivisch eine bidirektionale, aber kontrollierte Kommunikation zwischen den operativen Anlagen (Zone 4) und den IT-Systemen (Zone 1). Das mehrstufige Sicherheits- und Zonenmodell gewährleistet damit eine strikte Trennung von IT- (*Information Technology*) und OT-Systemen (*Operational Technology*), während gleichzeitig über definierte Schnittstellen und Protokolle (z. B. OPC UA, MQTT, HTTPS) ein sicherer Datenaustausch ermöglicht wird. Ergänzt wird die Architektur durch virtualisierte Serverlandschaften und redundante Netzwerkkomponenten, die eine hohe Verfügbarkeit und Skalierbarkeit der IT-Services sicherstellen.

6.2.4 Datenerfassung mittels Sensorik

Aufbauend auf der dargestellten IT-Architektur und dem zugrunde liegenden Sicherheits- und Zonenmodell kommt den Condition-Monitoring-Systemen (CMS) sowie der eingebetteten Sensorik eine zentrale Rolle innerhalb der technischen Infrastruktur zu. Sie bilden die primären Datenquellen für die Überwachung und Analyse des Anlagenzustands und stellen somit die operative Grundlage für datengetriebene Instandhaltungsstrategien dar. Die im Produktionsumfeld des Presswerks eingesetzten CMS sind in der Regel in der Zone 3 verortet und über standardisierte Kommunikationsprotokolle mit der Anlagenebene (Zone 4) und den übergeordneten IT-Systemen (Zone 2) verbunden. Diese Systeme erfassen kontinuierlich maschinen- und prozessrelevante Messgrößen und ermöglichen so eine zustandsorientierte Beobachtung der Anlagenkomponenten.

In der realen Anlagenanbindung erfolgt die Datenerfassung über ein mehrstufiges, hierarchisches Kommunikationskonzept, das im Wesentlichen auf Komponenten eines marktführenden Automatisierungsanbieters basiert. Auf der untersten Ebene sind verschiedene




Abbildung 18: Bestandsaufnahme der bestehenden IT-Architektur im Presswerk

analoge und digitale Sensoren installiert, die direkt mit dezentralen Condition-Monitoring-Knoten verbunden sind. Diese Knoten fungieren als lokale Sammelpunkte für Sensordaten und übernehmen teilweise bereits Vorverarbeitungs- und Filterfunktionen. Die erfassten Messwerte werden über ein industrielles Kommunikationsprotokoll an ein zentrales CMS weitergeleitet. Dieses System ist über standardisierte Feldbus- und Ethernet-basierte Schnittstellen mit der Automatisierungs- und Steuerungsebene der Anlage verbunden. Dort sind mehrere speicherprogrammierbare Steuerungen (SPS) und Antriebssteuerungen integriert, die den Datenfluss zwischen Sensorik, Aktorik und übergeordneten Produktionssystemen koordinieren. Über definierte Softwareknoten innerhalb des Produktionsnetzes werden die Messdaten aggregiert und für weiterführende Analysen bereitgestellt. Die Visualisierung und Analyse der Zustandsdaten erfolgt über eine zentrale Monitoring-Software, die in einer Client-Server-Architektur betrieben wird. Mehrere Arbeitsstationen (Clients) greifen dabei auf einen Server zu, der als Datenknotenpunkt innerhalb des Produktionsnetzes fungiert. Zudem werden die erhobenen Daten an einen übergeordneten Datenserver übertragen, auf dem eine strukturierte, langfristige Speicherung und Aufbereitung der Informationen erfolgt. Das im Presswerk eingesetzte CMS basiert auf der Softwarelösung X-Tools des Herstellers Siemens. Diese Plattform ist speziell für die Zustandsanalyse und Datenverwaltung in industriellen Anlagen konzipiert und dient als zentrales Werkzeug zur Erfassung, Auswertung und Visualisierung der von den Condition-Monitoring-Modulen erfassten Messdaten. Über standardisierte Schnittstellen, wie OPC UA, werden die erfassten Daten an übergeordnete Systeme der Produktions- und IT-Ebene übergeben. X-Tools unterstützt die strukturierte Erfassung und Aggregation von Schwingungs-, Temperatur- und Prozessdaten und bietet Analysefunktionen für Trendauswertungen, Alarmmanagement und Berichtserstellung [vgl. Siemens AG 2025]. Die Architektur der Software folgt einem Client-Server-Prinzip, das es ermöglicht, sowohl lokal als auch remote auf aktuelle und historische Messdaten zuzugreifen. Damit fungiert X-Tools als Bindeglied zwischen

der operativen Sensorebene und den datengetriebenen Instandhaltungsprozessen und stellt eine zentrale Komponente innerhalb der technischen Infrastruktur des Presswerks dar. Ein wesentliches Merkmal des eingesetzten Systems besteht darin, dass die durch X-Tools erfassten und gespeicherten Daten in einem proprietären Format vorliegen. Dieses Format ist speziell auf die interne Struktur der Software abgestimmt und optimiert die Verarbeitung innerhalb der Siemens-Systemumgebung. Für weiterführende datenanalytische Anwendungen erfordert dies jedoch eine entsprechende Konvertierung oder Extraktion der Daten in standardisierte, analysierbare Formate. Somit stellt die Datenaufbereitung einen entscheidenden Schritt dar, um eine Integration in die im späteren Verlauf dieser Arbeit vorgestellte intelligente Data Pipeline zu ermöglichen.

Die zuvor beschriebene Systemarchitektur verdeutlicht, dass im Presswerk bereits eine umfassende technische Infrastruktur zur kontinuierlichen Erfassung und Bereitstellung von Zustands- und Prozessdaten besteht. Aufbauend darauf werden im Folgenden die konkret erfassten Messdaten sowie die verwendeten Datenschnittstellen dargestellt, über die diese Informationen an das übergeordnete Datenmanagement übermittelt werden. Die Analyse der erhobenen Daten bildet die Grundlage, um den Informationsfluss innerhalb der Produktionsumgebung vollständig nachzuvollziehen und deren Eignung für weiterführende Anwendungen im Rahmen der intelligenten Data Pipeline zu bewerten. Als Referenzanlage und zentrale Datenquelle für Implementierung des Referenzmodells der intelligenten Data Pipeline sowie der Data Mining Anwendungen wurde eine Pressenlinie identifiziert, die sowohl in die technische Infrastruktur eingebettet ist als auch eine Vielzahl von physikalischen und prozessrelevante Messgrößen erfasst. Insgesamt werden zur Zeit der Betrachtung 664 Messgrößen kontinuierlich aufgezeichnet, wodurch ein Datenvolumen von durchschnittlich 3,5 Terabyte pro Woche entsteht. Die erfassten Messgrößen lassen sich inhaltlich in vier Hauptkategorien gliedern, die unterschiedliche physikalische und prozessrelevante Aspekte der Pressenlinie abbilden. Die erste Gruppe umfasst allgemeine Messgrößen mit insgesamt 160 Signalen, die Parameter wie Wassergehalt, Schmierstoffqualität oder Temperaturverläufe beinhalten. Diese Größen liefern wesentliche Informationen über die Betriebsbedingungen und den Zustand der verwendeten Medien und dienen damit der übergeordneten Prozessüberwachung. Die zweite Kategorie bilden die Presskraft- und Ziehkissenmessgrößen mit insgesamt 164 erfassten Signalen. Hierbei werden unter anderem Dehnung, Kippmoment und Schwerpunktverlagerungen aufgezeichnet, um Rückschlüsse auf die Lastverteilung, die Prozessstabilität und den Einfluss mechanischer Kräfte im Umformprozess zu ermöglichen. Eine weitere Gruppe stellen die sogenannten Transfermessgrößen dar, von denen 308 Signale erfasst werden. Diese beschreiben elektrische und mechanische Zustandsgrößen wie Strom, Drehzahl oder Position der Transferachsen und liefern damit eine detaillierte Abbildung der Bewegungsabläufe sowie der Synchronisation innerhalb der Pressenlinie. Abschließend werden 32 Schwingungsmessgrößen aufgezeichnet, die über Sensoren an Antriebssträngen, Lagerstellen und anderen rotierenden Komponenten erfasst werden. Sie bilden die Grundlage für die Zustandsüberwachung mechanischer Baugruppen und ermöglichen die frühzeitige Erkennung potenzieller Unregelmäßigkeiten oder Verschleißerscheinungen. Die Datenerfassung erfolgt mit unterschiedlichen zeitlichen Auflösungen, die von hochfrequenten Schwingungssignalen im Millisekundenbereich bis zu

langsameren Prozessgrößen im Sekunden- oder Minutenraster reichen. Die Übertragung der Signale an die zentrale Condition-Monitoring-Software erfolgt über standardisierte industrielle Kommunikationsprotokolle wie PROFIBUS, Ethernet und OPC UA. Dort werden die Messwerte strukturiert gespeichert, visualisiert und für Trendanalysen sowie Zustandsdiagnosen aufbereitet.

Zusammenfassend zeigt sich, dass in der betrachteten Pressenlinie eine umfangreiche und tief integrierte Datenerfassung realisiert ist, die eine nahezu lückenlose Abbildung der relevanten Prozess- und Zustandsgrößen ermöglicht. Durch die systematische Erfassung und strukturierte Bereitstellung dieser Daten entsteht eine belastbare Informationsbasis, die weit über klassische Instandhaltungszwecke hinausgeht. Sie bildet die Grundlage für weiterführende datengetriebene Analysen und eröffnet das Potenzial, mithilfe geeigneter Data-Mining-Methoden Muster, Abhängigkeiten und Anomalien zu identifizieren. Damit stellt die vorhandene Messdateninfrastruktur eine entscheidende Grundlage für die Entwicklung und Implementierung der im weiteren Verlauf dieser Arbeit beschriebenen Data-Mining-Methoden im Presswerk.

6.2.5 Anlagenerfassungssysteme

Neben den automatisierten CMS bilden die Anlagenerfassungssysteme eine weitere tragende Säule der technischen Infrastruktur im Presswerk. Während erstere überwiegend sensorbasiert arbeiten und den physikalischen Zustand der Maschinen überwachen, konzentrieren sich die Anlagenerfassungssysteme auf die Erfassung und Dokumentation betriebsnaher, domänenspezifischer Informationen, die unmittelbar durch das Prozess- und Erfahrungswissen der Anlagenführer und Instandhaltungsteams entstehen. Diese Systeme sind somit ein wesentlicher Bestandteil des digitalen Abbilds der Produktionsrealität und tragen entscheidend zur Transparenz und Nachvollziehbarkeit von Anlagen- und Prozessereignissen bei.

Ein zentrales System stellt hierbei die **Produktionsleitsteuerung** dar, die der Auftragsplanung und Auftragssteuerung dient und den Anlagenführern sämtliche produktionstechnisch relevanten Informationen, wie das zu fertigende Bauteil, die Soll-Stückzahl und die Folgeaufträge, in Echtzeit bereitstellt. Durch diese Integration in die operative Ebene können anstehende Werkzeugwechsel oder Rüstvorgänge frühzeitig vorbereitet werden, was zu einer messbaren Reduzierung von Stillstands- und Nebenzeiten führt. Darüber hinaus fungiert der sogenannte **Werkerdialo** als Schnittstelle zwischen Mensch und Maschine. Er ist direkt mit der Anlagensteuerung verbunden und dient der Erfassung von Stillständen, Fehlern und Qualitätsabweichungen. Tritt ein Stillstand auf, wird automatisch ein Eintrag erzeugt, der durch den Anlagenführer nach Abschluss der durchgeführten Instandhaltungsmaßnahme zu kategorisieren und informativ zu ergänzen ist. Diese Einträge werden anschließend in das **Anlagenbuch** überführt, das als historisches Register sämtlicher Stillstandereignisse dient. Auf diese Weise wird eine transparente Nachverfolgbarkeit der Anlagenhistorie geschaffen. Das Anlagenbuch strukturiert die erfassten Ereignisse in mehreren Spalten, die unter anderem Anlagen-ID, Kostenstelle, Störungsdauer, Störungstyp, Zeitstempel und Bemerkungen enthalten. Die Störungstypen sind in neun Hauptkategorien gegliedert, die eine systematische Klassifikation der Ursachen und Kontexte von Anla-

genstillständen ermöglichen. Diese Kategorien unterscheiden sich sowohl hinsichtlich ihres technischen Ursprungs als auch ihrer organisatorischen Einflüsse auf den Produktionsprozess. Technische Störungen umfassen Optimierungs- oder Reparaturmaßnahmen an Werkzeugen, Transfersystemen oder Abstapelanlagen und treten häufig infolge mechanischer oder steuerungstechnischer Fehlfunktionen auf. Logistische Störungen entstehen dagegen durch fehlendes Material oder Leergut und sind Ausdruck von Unstimmigkeiten in der Materialbereitstellung oder innerbetrieblichen Logistik. Betriebliche Störungen resultieren meist aus prozessbedingten Qualitätskontrollen nach Fehlererkennung und spiegeln die unmittelbare Reaktion auf Abweichungen im Fertigungsergebnis wider. Einen Sonderfall stellen die Auftragsnebenzeiten dar, zu denen Tätigkeiten wie Wartung, Reinigung oder das Wechseln von Teilebehältern zählen. Sie sind planmäßig erforderlich, führen jedoch aus Sicht der Produktionszeit zu temporären Unterbrechungen. Organisatorische Störungen wie Pausen, Schichtwechsel oder Informationsrunden sind ebenfalls nicht technischer Natur, wirken sich aber auf die Anlagenverfügbarkeit aus und werden deshalb dokumentiert. Zu den rüstbezogenen Kategorien zählen Rüststörungen und Rüstvorgänge selbst. Erstere treten auf, wenn während des Werkzeugwechsels unerwartete Probleme auftreten. Letztere hingegen sind planmäßige Stillstandszeiten, die durch die Umstellung auf andere Werkzeuge oder Bauteilvarianten entstehen. Ergänzt werden diese Kategorien durch undefinierte Störungen, bei denen keine nähere Ursache angegeben wurde, sowie minimale Störungen, die kurzzeitig auftreten und häufig ohne manuelle Eintragung bleiben. Diese differenzierte Kategorisierung ermöglicht eine strukturierte Auswertung der Stillstände und liefert wertvolle Einblicke in die Ursachen und Häufigkeiten von Produktionsunterbrechungen. Besonders die Bemerkungsspalte hat hierbei einen hohen inhaltlichen Wert, da sie freie Texteingaben der Anlagenführer enthält, in denen häufig Ursachen, betroffene Baugruppen oder durchgeführte Maßnahmen beschrieben werden. Diese Texte bilden einen qualitativen Datenbestand, der das Erfahrungswissen der Mitarbeitenden dokumentiert und sich perspektivisch für textanalytische Verfahren im Rahmen von Data-Mining-Anwendungen nutzen lässt. Ergänzend zum Anlagenbuch wird im Presswerk das **Werkstattbuch** geführt, das alle Instandhaltungs- und Instandsetzungsmaßnahmen systematisch dokumentiert. Die Struktur umfasst Informationen zu Datum, Ort, verantwortlicher Organisationseinheit und Art der Maßnahme. Durch die eindeutige Zuordnung von Einträgen im Werkstattbuch zu Ereignissen im Anlagenbuch entsteht eine semantische Verknüpfung zwischen Störereignissen und durchgeführten Instandhaltungsaktivitäten. Dies ermöglicht eine gezielte Korrelation zwischen den aufgetretenen Stillständen und den ergriffenen Maßnahmen. Dieser Aspekt ist von zentraler Bedeutung für spätere datenanalytische Auswertungen, insbesondere im Hinblick auf die Umsetzung einer präskriptive Instandhaltungsstrategie. Sowohl das Anlagenbuch, als auch das Werkstattbuch bilden nicht nur operative Werkzeuge der Instandhaltungsorganisation, sondern zugleich wertvolle Wissensspeicher, die domänenspezifisches Expertenwissen in strukturierter Form abbilden. Im Kontext der technischen Infrastruktur fungieren sie als Bindeglied zwischen der automatisierten Datenerfassung und dem menschlichen Erfahrungswissen und tragen entscheidend dazu bei, das reale Prozessgeschehen datenbasiert interpretierbar zu machen.

Die aufgeführten Anlagenerfassungssysteme des Presswerkes sind eingebettet in einem

übergeordneten Betriebsdatenerfassungssystem (BDE). Dieses dient als zentrale Plattform zur Sammlung, Zusammenführung und strukturierten Bereitstellung sämtlicher anlagenbezogener Ist-Daten und verknüpft damit technische Prozessinformationen aus den Steuerungssystemen mit den manuell erfassten Einträgen aus den domänenspezifischen Dokumentationssystemen. Über standardisierte Datenschnittstellen werden Produktions-, Stillstands- und Qualitätsinformationen aus den Anlagensteuerungen sowie aus dem Werkdialog in Echtzeit an das BDE übermittelt. Innerhalb des Systems werden diese Informationen zeitsynchron zusammengeführt, wodurch ein konsistentes und vollständiges Abbild des Produktionsgeschehens entsteht. Auf dieser Grundlage können übergeordnete Systeme oder Fachabteilungen Berichte, Auswertungen und Kennzahlen ableiten, die zur Beurteilung der Leistung, Verfügbarkeit und Qualität einzelner Anlagen dienen. Ein wesentlicher Mehrwert des BDE-Systems liegt in der strukturierten Verknüpfung der verschiedenen Datenquellen. So werden Störungsursachen, Instandsetzungsmaßnahmen und zeitliche Verläufe aus unterschiedlichen Quellen konsistent zusammengeführt und in relationalen Datenstrukturen gespeichert. Dadurch wird eine historische Rückverfolgung von Ereignissen, die manuelle Identifikation wiederkehrender Muster und eine konsistente Beurteilung von Anlagenverhalten ermöglicht. Der Zugriff auf die in dem BDE gespeicherten Daten erfolgt zur Zeit der Betrachtung ausschließlich manuell über die Benutzeroberfläche des Systems. Ein automatisierter oder kontinuierlicher Datenzugriff, etwa über eine Schnittstelle oder ein API-basiertes Verfahren, ist nicht implementiert. Nutzerinnen und Nutzer können lediglich zeitlich begrenzte Datenintervalle gezielt auswählen und exportieren, um bestimmte Produktionszeiträume oder Ereignisse detaillierter auszuwerten. Der Datenexport selbst erfolgt ebenfalls manuell, was den Zugriff auf größere Datenmengen oder eine regelmäßige, systematische Datenausleitung erheblich einschränkt. Alle systemgenerierten Bücher, wie das Anlagenbuch und das Werkstattbuch, lassen sich jedoch in gängigen, datenanalytisch weiterverarbeitbaren Formaten, insbesondere .csv-Dateien, exportieren. Dadurch besteht grundsätzlich die Möglichkeit, die Daten außerhalb des Systems weiter zu verarbeiten und für analytische oder wissenschaftliche Zwecke aufzubereiten. Aufgrund der fehlenden Automatisierung erfordert dieser Prozess jedoch einen hohen manuellen Aufwand und ist damit für kontinuierliche oder großvolumige Datenanalysen nur eingeschränkt geeignet. Im Kontext dieser Arbeit ist dieser Umstand von besonderer Relevanz, da er die technische Notwendigkeit einer automatisierten Datenintegration verdeutlicht. Die manuelle Zugriffsbeschränkung stellt gegenwärtig eine Barriere für eine kontinuierliche Datenbereitstellung dar, wie sie für datengetriebene Anwendungen, insbesondere für die Umsetzung der intelligenten Data Pipeline, erforderlich ist.

6.2.6 Zwischenfazit der systematischen Bestandsaufnahme

Die durchgeführte systematische Bestandsaufnahme hat gezeigt, dass im betrachteten Presswerk bereits eine umfassende und tief integrierte technische Infrastruktur existiert, die eine solide Grundlage für datengetriebene Anwendungen bildet. Sowohl auf der Sensor- und Automatisierungsebene als auch in den übergeordneten IT- und Anlagenerfassungssystemen sind Strukturen etabliert, die eine durchgängige Erfassung, Speicherung und Bereitstellung von Zustands- und Prozessdaten ermöglichen. Ergänzt wird diese technische

Basis durch ineinandergreifende organisatorische Instandhaltungsstrukturen, die eine enge Zusammenarbeit zwischen den beteiligten Fachbereichen gewährleisten. Durch die klare funktionale Aufteilung und zugleich abgestimmte Kommunikation zwischen den Einheiten der Instandhaltung wird eine hohe operative Effizienz in der Störungsdiagnose, Fehlerbehebung und Anlagenoptimierung erreicht. Insbesondere die Kombination aus CMS, BDE, domänenspezifischen Anlagendokumentationen und den strukturierten Instandhaltungsprozessen verdeutlicht, dass in der Produktionsdomäne ein hohes Maß an technischer Reife, Datentransparenz und organisatorischer Integration erreicht wurde. Diese ganzheitliche Verknüpfung von Technik, Daten und Domänenwissen bildet die Grundlage für die datengetriebene Weiterentwicklung der Instandhaltungsprozesse und bietet damit ideale Voraussetzungen für die Umsetzung des Referenzmodells der intelligenten Data Pipeline sowie die Anwendung fortgeschrittener Data-Mining-Methoden.

Die Bestandsaufnahme hat zugleich zentrale Herausforderungen offengelegt, die bei der praktischen Realisierung datenbasierter Anwendungen berücksichtigt werden müssen. Dazu gehört das proprietäre Datenformat der CMS, das eine direkte Integration und Weiterverarbeitung der Sensordaten erschwert und eine vorherige Konvertierung in standardisierte Austauschformate erfordert. Ebenso ist das vorhandene domänenspezifische Wissen bislang nicht automatisiert verfügbar, sondern in Form freitextlicher Einträge in Anlagen- und Werkstattbüchern dokumentiert. Diese Informationen sind inhaltlich wertvoll, jedoch stark individuell formuliert, wodurch sie anfällig für grammatikalische Fehler, uneinheitliche Ausdrucksweisen und semantische Mehrdeutigkeiten sind. Darüber hinaus existieren innerhalb der bestehenden IT-Infrastruktur spezifische Herausforderungen, die aus der netzwerktechnischen Zonierung und den Sicherheitsarchitekturen resultieren. Das Presswerk arbeitet auf Grundlage eines mehrstufigen Sicherheits- und Zonenmodells, das den Datenaustausch zwischen Produktionsnetz und Office-IT streng reglementiert. Die Kommunikation über die verschiedenen Ebenen hinweg erfolgt ausschließlich über klar definierte DMZ und ist durch Firewall-Regelwerke kontrolliert. Diese Architektur gewährleistet ein hohes Maß an IT-Sicherheit, führt jedoch gleichzeitig zu Restriktionen im bidirektionalen Datentransfer zwischen den Zonen. Insbesondere für die Umsetzung einer durchgängigen, automatisierten Datenkommunikation stellt diese Segmentierung eine wesentliche Hürde dar. Daten aus dem Produktionsnetz können nur durch enormen Aufwand in übergeordnete IT-Systeme übertragen werden, da jeder Zugriff über Firewalls, Proxys oder Gateways spezifisch freigeschaltet und sicherheitstechnisch geprüft werden muss. Dadurch entsteht eine technische Trennung zwischen operativer und analytischer Ebene, die einerseits dem Schutz der Produktionssysteme dient, andererseits aber die Integration und Synchronisation von Datenströmen erschwert. Diese strukturellen Gegebenheiten verdeutlichen, dass für die Umsetzung datengetriebener Anwendungen nicht nur eine semantische und technische Harmonisierung der Daten erforderlich ist, sondern auch infrastrukturelle Anpassungen. Damit wird deutlich, dass die technische Architektur, das domänenspezifische Wissen und die organisatorischen Strukturen im Presswerk bereits wesentliche Voraussetzungen für eine datengetriebene Instandhaltungsumgebung schaffen, zugleich aber auch gezielte Erweiterungen erfordern, um diese Potenziale vollständig zu entfalten.

Diese Heterogenität stellt hohe Anforderungen an die spätere Datenaufbereitung, Inte-

gration und Harmonisierung, verdeutlicht aber zugleich den großen Erkenntniswert, der in der Kombination aus strukturierten Maschinendaten und unstrukturiertem Erfahrungswissen liegt. Zusammenfassend lässt sich festhalten, dass die betrachtete Produktionsdomäne sowohl strukturell als auch organisatorisch über ein hohes Reifegradniveau verfügt und damit eine geeignete Ausgangsbasis für die Entwicklung und Implementierung Referenzmodells der intelligenten Data Pipeline sowie die Anwendung der Data-Mining-Methoden darstellt. Die identifizierten Herausforderungen markieren gleichzeitig die zentralen Ansatzpunkte für deren konzeptionelle und technologische Ausgestaltung, insbesondere im Hinblick auf Datenintegration, Standardisierung, IT-seitige Schnittstellenarchitekturen sowie die semantische Interpretation von Instandhaltungswissen.

6.3 Integration des Referenzmodells

Nach der konzeptionellen Entwicklung und theoretischen Fundierung der intelligenten Data Pipeline in **Kapitel 5** bildet die Integration des Referenzmodells in die reale Produktionsumgebung den methodischen Übergang von der konzeptionellen Gestaltung zur anwendungsnahen Umsetzung des entwickelten Artefakts. In diesem Schritt wird das Referenzmodell aus seinem abstrakten Entwurfsrahmen herausgelöst und in einen konkreten industriellen Anwendungskontext eingebettet, um dessen technische Anschlussfähigkeit und strukturelle Umsetzbarkeit unter realen Rahmenbedingungen aufzuzeigen. Während die Gestaltungsphase auf die Entwicklung eines theoretisch konsistenten und methodisch begründeten Referenzmodells abzielt, fokussiert die Integrationsphase dessen exemplarische Realisierung innerhalb einer bestehenden sozio-technischen Produktionsumgebung. Ziel ist es dabei nicht, das Referenzmodell bereits abschließend zu bewerten, sondern dessen prinzipielle Anwendbarkeit, architektonische Einbettbarkeit und funktionale Durchgängigkeit im operativen Umfeld transparent darzustellen. Die Umsetzung erfolgt im Rahmen einer eingebetteten Multifallstudie, die es erlaubt, das Referenzmodell nicht isoliert, sondern in Wechselwirkung mit bestehenden technischen, organisatorischen und prozessualen Strukturen der betrachteten Produktionsdomäne zu analysieren (vgl. **Kapitel 6.1**). Auf diese Weise wird eine empirisch fundierte Demonstration der Modellintegration ermöglicht, ohne den Anspruch einer vollständigen Evaluation vorwegzunehmen. Die Integration verfolgt dabei zwei komplementäre Zielrichtungen. Erstens wird aufgezeigt, in welchem Umfang das in **Kapitel 5** entwickelte Referenzmodell unter den gegebenen infrastrukturellen und organisatorischen Randbedingungen einer industriellen Brownfield-Umgebung realisiert werden kann. Zweitens werden die notwendigen technischen, organisatorischen und informationellen Anpassungen identifiziert, die erforderlich sind, um eine durchgängige und konsistente Datenkette von der Datenerhebung über die Vorverarbeitung bis hin zur analytischen Nutzung abzubilden. Die Integrationsphase fungiert damit als Demonstrator der operativen Anschlussfähigkeit der intelligenten Data Pipeline im industriellen Anwendungskontext.

Das Kapitel gliedert sich in drei inhaltlich aufeinander aufbauende Abschnitte. In **Kapitel 6.3.1** erfolgt zunächst die konzeptionelle Einordnung des Referenzmodells in die bestehende IT- und OT-Infrastruktur des betrachteten Presswerks, wobei zentrale Integrationsmechanismen und architektonische Kopplungspunkte herausgearbeitet werden. Darauf aufbauend wird in **Kapitel 6.3.2** die konkrete technische Umsetzung beschrieben,

einschließlich der realisierten Systemarchitektur, der eingesetzten Kommunikationsmechanismen sowie der verwendeten Edge- und Cloud-Komponenten. Ein abschließendes Zwischenfazit in **Kapitel 6.3.3** fasst die gewonnenen Erkenntnisse zusammen und schafft die inhaltliche Grundlage für die nachfolgenden Anwendungsfälle sowie die spätere, explizite Bewertung des Referenzmodells.

6.3.1 Theoretische Einbettung in die bestehende Infrastruktur

Die Integration des in **Kapitel 5** entwickelten Referenzmodells einer intelligenten Data Pipeline erfolgt in eine bestehende, hochkomplexe und sicherheitskritische IT- und OT-Infrastruktur des betrachteten Presswerks. Ziel dieser theoretischen Einbettung ist es, die strukturelle Anschlussfähigkeit des Referenzmodells an die vorhandene Systemlandschaft aufzuzeigen und dessen konzeptionelle Vereinbarkeit mit den realen architektonischen und sicherheitstechnischen Rahmenbedingungen industrieller Produktionsumgebungen darzustellen.

Die bestehende IT- und OT-Architektur ist, wie in **Kapitel 6.2.3** beschrieben, nach einem mehrstufigen Zonen- und Sicherheitsmodell aufgebaut, das eine physische und logische Trennung zwischen Produktionsnetzwerken und übergeordneten IT-Systemen vorsieht. Die Kommunikation zwischen den Zonen erfolgt ausschließlich über kontrollierte Übergabepunkte und DMZ-Strukturen und unterliegt klar definierten Firewall- und Sicherheitsrichtlinien. Dieses nach dem *Defense-in-Depth*-Prinzip ausgelegte Architekturkonzept stellt sicher, dass Sicherheitsmechanismen nicht auf einzelnen Schutzmaßnahmen beruhen, sondern durch mehrere, aufeinander abgestimmte Ebenen realisiert werden. Vor diesem Hintergrund ist das Referenzmodell so konzipiert, dass es die bestehende Infrastruktur funktional erweitert, ohne deren Sicherheitslogik zu umgehen oder zu unterlaufen. Es fungiert als vermittelnde Schicht zwischen der operativen Datenerzeugung in der Produktion und datenanalytischen sowie wissensbasierten Verarbeitungsmechanismen auf IT-Ebene. Die in **Abbildung 19** dargestellte Architektur verdeutlicht die theoretische Einbettung der einzelnen Referenzmodellebenen in die zonenkonforme Infrastruktur des Presswerks.

Auf der untersten Infrastrukturebene (Zone 4) befinden sich die Produktionsanlagen und eingebetteten Steuerungssysteme, die kontinuierlich Prozess-, Maschinen- und Zustandsdaten generieren und damit die primäre Datenquelle der intelligenten Data Pipeline darstellen (vgl. **Kapitel 5.2**). Die Sensordaten werden in Zone 3 zunächst durch das CMS X-Tools erfasst und einer ersten lokalen Vorverarbeitung unterzogen. Zu den hier vorgesehenen Verarbeitungsschritten zählen unter anderem die Synchronisierung von Zeitstempeln, die Aggregation von Messwerten, die Berechnung technischer Kennzahlen sowie die Filterung von Störsignalen. Ergänzend ist in Zone 3 eine dedizierte Vorverarbeitungsinstantz vorgesehen, in der die zuvor in der Produktion erhobenen Sensordaten einer initialen technischen Aufbereitung unterzogen werden (vgl. **Kapitel 5.3**). Diese Vorverarbeitung erfolgt vorgelagert zur Informationsintegration und dient dazu, die Rohsignale aus der Anlagenebene in eine strukturierte und qualitätsgesicherte Form zu überführen. Die daraus resultierenden Datensätze repräsentieren standardisierte Anlagenzustände und bilden die maschinelle Datengrundlage für alle nachgelagerten Integrations- und Analyseprozesse. Die Übertragung dieser Daten in die höheren Infrastrukturebenen erfolgt zonenkonform über




Abbildung 19: Einbettung des Referenzmodells in die bestehende Infrastruktur

abgesicherte, unidirektionale Kommunikationspfade, sodass kein Rückkanal in Richtung der Produktionsnetzwerke besteht. Parallel zur sensorbasierten Datenerhebung wird Domänenwissen als zweite, vorgelagerte Datenquelle erfasst. Dieses liegt in Form textbasierter Anlagendokumentationen, Instandhaltungsberichten und Werkstattbüchern vor und wird unabhängig von den Maschinendaten erhoben. Auch dieses Wissen wird zunächst außerhalb der eigentlichen Informationsintegration gesammelt und in vorbereitender Form bereitgestellt (vgl. **Kapitel 5.3**). Die zentrale Informationsintegration ist in Zone 2 verortet und setzt erst nach Abschluss dieser vorgelagerten Erhebungs- und Vorverarbeitungsschritte an (vgl. **Kapitel 5.4**). In dieser Ebene werden die vorverarbeiteten strukturierten Sensordaten mit dem textuellen Domänenwissen zusammengeführt. Beide Datenströme werden dabei nicht mehr isoliert betrachtet, sondern semantisch miteinander verknüpft und in einer gemeinsamen Datenbasis abgelegt. Die Informationsintegration fungiert somit als nachgelagerte Verarbeitungsschicht, die auf bereits erhobenen und aufbereiteten Daten aufsetzt und diese in einen gemeinsamen analytischen und semantischen Kontext überführt. Eng gekoppelt an die Informationsintegration ist die ebenfalls in Zone 2 angesiedelte Wissensdatenbank (vgl. **Kapitel 5.7**). Sie dient der persistenten Speicherung historischer Ereignisse, dokumentierter Instandhaltungsmaßnahmen und analytischer Befunde. Zwischen Informationsintegration und Wissensdatenbank besteht eine bidirektionale Verbindung, die sowohl die Nutzung vorhandenen Wissens für Labeling- und Anreicherungsprozesse als auch die kontinuierliche Erweiterung der Wissensbasis durch neue Erkenntnisse ermöglicht. Nach Abschluss der Vorverarbeitung und semantischen Anreicherung werden konsolidierte Datensätze über ein Edge Device (Zone 1a) in eine Cloud-Umgebung übertragen (vgl. **Kapitel 5.8**). Diese stellt die erforderliche Rechenleistung und Skalierbarkeit für komplexe

Modellierungs-, Trainings- und Validierungsprozesse bereit. Die dort entwickelten Modelle werden nach Abschluss der Trainings- und Validierungsschritte auf einen performanten Rechner in Zone 1 übertragen, der in direkter Verbindung zu nahezu in Echtzeit bereitgestellten Anlagendaten steht und die operative Analyse übernimmt (vgl. **Kapitel 5.5**). Da sich Prozessbedingungen und Anlagenzustände im Zeitverlauf verändern, ist in der Architektur ein kontinuierliches Modellmonitoring vorgesehen. Dabei werden Leistungskennzahlen der Modelle im operativen Betrieb überwacht und Abweichungen systematisch erfasst. Überschreiten diese definierte Schwellenwerte, kann ein Nachtrainierungsprozess angestoßen werden, der in der Cloud-Umgebung unter Nutzung historischer und neu gelabelter Daten erfolgt. Aktualisierte Modelle werden anschließend erneut in die operative Umgebung überführt. Die im operativen Betrieb erzeugten Analyseergebnisse der Zone 1 werden nicht ausschließlich für interne Modellbewertungen genutzt, sondern gezielt an die Überwachungsebene übermittelt (vgl. **Kapitel 5.6**). Zu diesen Ergebnissen zählen insbesondere Zustandsbewertungen, Prognosen, Anomalieindikatoren sowie modellinterne Vertrauens- und Qualitätskennzahlen. Die Übertragung erfolgt über eine definierte, zonenkonforme Schnittstelle, die sicherstellt, dass ausschließlich aggregierte und interpretierbare Analyseoutputs – nicht jedoch Rohdaten oder Modellparameter – in die Überwachungsebene gelangen. In der Überwachungsebene werden diese Analyseergebnisse mit dem in der Wissensdatenbank abgelegten Erfahrungs- und Entscheidungswissen kontextualisiert und in geeigneter Form visualisiert. Die Übermittlung stellt damit den Übergang von der datengetriebenen Analyse zur handlungsorientierten Entscheidungsunterstützung dar. Gleichzeitig ermöglicht die klare Trennung zwischen Analyse- und Überwachungsebene, dass die operative Modellverarbeitung von der nutzerzentrierten Darstellung und Interpretation entkoppelt bleibt, ohne die inhaltliche Konsistenz der Entscheidungsgrundlagen zu beeinträchtigen. Darüber hinaus besteht zwischen der Überwachungsebene und der Wissensdatenbank eine bidirektionale Kopplung, die eine semantische Rückführung von Analyseergebnissen ermöglicht. Auf diese Weise können erkannte Anomalien oder Defekte in den Kontext historischer Fälle eingeordnet und für die Ableitung von Handlungsempfehlungen genutzt werden, während neue Erkenntnisse zugleich zur Erweiterung der Wissensbasis beitragen.

Insgesamt verdeutlicht die dargestellte Architektur die Rolle des Referenzmodells als integrative und adaptive Schicht zwischen operativer Datenerfassung, wissensbasierter Kontextualisierung und datengetriebener Analyse. Die strikte Zonierung stellt dabei sicher, dass sämtliche Datenflüsse sicherheitskonform über klar definierte Kommunikationspfade erfolgen, während die hybride Ausgestaltung aus Edge- und Cloud-Komponenten eine skalierbare und flexible Umsetzung datenanalytischer Verfahren ermöglicht. Die theoretische Einbettung schafft damit die architektonische Grundlage für die nachfolgende technische Implementierung und die anwendungsnahe Betrachtung des Referenzmodells.

6.3.2 Technische Implementierung

Die zunächst theoretische Einbettung des Referenzmodells der intelligenten Data Pipeline in die bestehende Infrastruktur im vorangegangenen Kapitel wird im Folgenden in die reale Produktionsumgebung des Presswerks übertragen und hinsichtlich ihrer technischen

Umsetzbarkeit sowie ihrer funktionalen Leistungsfähigkeit validiert. Ziel dieses Kapitels ist es, die Überführung des konzeptionellen Modells in ein implementiertes System zu beschreiben und den Nachweis zu erbringen, dass die im Design postulierten Prinzipien unter realen industriellen Bedingungen praktisch anwendbar sind. Die Vorgehensweise orientiert sich dabei an den methodischen Leitlinien des DSR, in deren Zentrum die Gestaltung, Implementierung und Evaluation von Artefakten steht, die sowohl wissenschaftlichen Erkenntnisgewinn als auch praktischen Nutzen generieren [vgl. Hevner et al. 2004, S. 75–78]. Innerhalb des DSR-Prozesses markiert die Implementierung die Phase der *Build*-Aktivität, in der die zuvor entworfene Artefaktstruktur realisiert und in einen Anwendungskontext überführt wird. Gleichzeitig ist die Implementierung unmittelbar mit der späteren in **Kapitel 7** aufgeführten *Evaluate*-Phase verknüpft, da die Bewertung des Artefakts stets auf seiner funktionalen Realisierung basiert [vgl. Peffers et al. 2007, S. 55–59]. Zur Sicherstellung methodischer Nachvollziehbarkeit erfolgt die Umsetzung gemäß den Qualitätsanforderungen empirischer Fallstudienforschung (vgl. **Kapitel 2.5.2**). Während der DSR den Gestaltungsrahmen des Artefakts vorgibt, dient die empirische Struktur zur Untersuchung der Anwendbarkeit und Effektivität innerhalb einer realweltlichen Umgebung. Entsprechend wird die Implementierung als eingebettete Fallstudie konzipiert, bei der das Referenzmodell in die bestehende IT- und OT-Infrastruktur des Presswerks integriert und anhand realer Datenquellen und Prozesse überprüft wird. Die Verknüpfung beider methodischer Ansätze gewährleistet, dass die Implementierung sowohl konstruktiv als auch analytisch fundiert erfolgt. Die Realisierung des Referenzmodells für eine intelligente Data Pipeline erfolgt unter Berücksichtigung der bestehenden technischen, organisatorischen und infrastrukturellen Rahmenbedingungen des Presswerks. Dabei steht in diesem Abschnitt die praktische Umsetzung des zuvor theoretisch konzipierten Artefakts im Mittelpunkt, wobei die logisch-semantische Strukturierung über die Vorüberlegungen, dem architektonischen Entwurf, der konkreten Umsetzung sowie dessen Validierung verfolgt wird.

Ziel der vorangestellten Vorüberlegungen war es, die technische Anschlussfähigkeit und Integrationsfähigkeit des Referenzmodells sicherzustellen. Dabei wurden zunächst die bereits vorhandenen Systeme und Schnittstellen identifiziert, die für eine datenbasierte Instandhaltungsunterstützung von Relevanz sind. Dazu zählen insbesondere das CMS X-Tools, das BDE, das CM-Leitsystem mit der entsprechenden Visualisierungsmöglichkeit von Sensordaten, die produktionsnahen Steuerungsebenen sowie die zentralen IT-Management- und Sicherheitssysteme. Ergänzend wurden laufende Konzernkooperationen und strategische IT-Partnerschaften berücksichtigt, die den technologischen Rahmen für die Implementierung vorgeben, etwa hinsichtlich Cloud-Infrastruktur, Datenzugriffsrichtlinien und Edge-Technologien. Auf Basis dieser Analyse wurde festgestellt, dass der automatisierte Zugriff auf Produktions- und Zustandsdaten eine zentrale Voraussetzung für die Umsetzung des Referenzmodells darstellt. Nur durch eine kontinuierliche, automatisierte Datenerfassung kann die Data Pipeline die erforderliche Aktualität und Reaktionsgeschwindigkeit für Analyseverfahren gewährleisten. Entsprechend wurde als Gestaltungsprinzip definiert, dass sämtliche Messdaten über standardisierte Schnittstellen bereitgestellt und über sichere Kommunikationspfade in die übergeordneten Ebenen integriert werden.

Für die Integration des Domänenwissens in Form von der textbasierten Informationen

aus Anlagen- und Werkstattbüchern ergaben sich dagegen strukturelle Einschränkungen. Aufgrund der heterogenen Dokumentationsformen, der individuellen Ausdrucksweisen und der fehlenden maschinellen Schnittstellen ist eine vollständig automatisierte Einbindung dieser Daten in die Pipeline derzeit nicht realisierbar. Aus diesem Grund wurde ein hybrider Ansatz gewählt, dass das Domänenwissen manuell oder halbautomatisiert in die Informationsintegration eingebracht wird. Anschließend folgt die semantische Aufbereitung, Strukturierung sowie Wissensanreicherung. Darüber hinaus stellte sich der Zugriff auf das Domänenwissen selbst als organisatorische Herausforderung dar. Da die Fach- und Instandhaltungsexperten eng in die laufenden Produktionsprozesse eingebunden sind, war ihre zeitliche Verfügbarkeit zur Datenannotation und -validierung oftmals eingeschränkt. Dies führte dazu, dass das Labeling der Daten, insbesondere bei komplexen Störungsereignissen oder mehrdeutigen Textpassagen, nicht in allen Fällen zeitnah erfolgen konnte. Die begrenzte Verfügbarkeit domänenspezifischer Expertise stellt somit eine zusätzliche Herausforderung für die kontinuierliche Anreicherung und Validierung der Wissensbasis dar. Daraus ergibt sich ein klarer Bedarf nach einer Automatisierung des Labeling-Prozesses, um den hohen manuellen Aufwand zu reduzieren und die Datenanreicherung langfristig skalierbar zu gestalten. Zugleich zeigt sich die Notwendigkeit eines standardisierten Verfahrens zur Wissensaufnahme, das die Einheitlichkeit und Struktur der Einträge in den Anlagendokumentationen sicherstellt. Nur durch eine konsistente Erfassung von Störungs- und Instandhaltungsinformationen lassen sich sprachliche und semantische Varianzen minimieren und die Vorverarbeitung textbasierter Daten effizient automatisieren. Ein solches standardisiertes Vorgehen würde nicht nur die Qualität der Wissensbasis erhöhen, sondern auch die Integration von Erfahrungswissen in datengetriebene Analyseprozesse erheblich vereinfachen.

Im Rahmen der technischen Umsetzung wurden zudem die bestehenden strategischen Kooperationen des Konzerns mit Technologiepartnern berücksichtigt, die die Grundlage für eine skalierbare und zukunftsfähige Implementierungsarchitektur bilden. Eine zentrale Rolle nimmt hierbei die Cloud-Infrastruktur von Amazon Web Services (AWS) ein, die im Konzernumfeld als bevorzugte digitale Produktionsplattform (DPP) für datengetriebene Anwendungen etabliert ist. AWS bietet durch seine modularen Dienste, wie beispielsweise im Bereich von Data Storage, Machine Learning und Modell-Deployment, eine flexible und leistungsfähige Umgebung, die die in dieser Arbeit erforderlichen Modellierungs-, Trainings- und Validierungsprozesse der datenanalytischen Modelle in großem Umfang unterstützt. Insbesondere die Möglichkeit, rechenintensive Trainingsprozesse elastisch zu skalieren und Modelle versionsbasiert zu verwalten, stellt einen wesentlichen Vorteil für die Umsetzung der intelligenten Data Pipeline dar. Ergänzend hierzu wurden Edge-Technologien der Firma Siemens betrachtet, die eine sichere und latenzarme Kommunikation zwischen der produktionsnahen Ebene und der Cloud-Umgebung ermöglichen. Diese Edge-Komponenten fungieren als Vermittlungsschicht, die Daten aus den Produktionssystemen lokal aggregiert, vorverarbeitet und über verschlüsselte Protokolle an die Cloud überträgt. Der Einsatz von Siemens-Edge-Systemen bietet den Vorteil einer nativen Kompatibilität mit den im Presswerk eingesetzten Automatisierungssystemen und Condition-Monitoring-Lösungen. Da das eingesetzte CMS X-Tools ebenfalls von Siemens stammt und Daten in einem pro-

prietären Siemens-spezifischen Format erfasst, ergibt sich eine strategische und technologische Synergie, die die Integration von Siemens-basierten Lösungen entlang der gesamten Datenverarbeitungskette begünstigt. Die Nutzung Siemens-eigener Edge- und Kommunikationslösungen ermöglicht eine durchgängige Interoperabilität zwischen den Ebenen der Datenerfassung, Vorverarbeitung und Informationsintegration. Gleichzeitig reduziert diese Systemhomogenität die Komplexität der Schnittstellenkonfiguration und minimiert potenzielle Kompatibilitätsprobleme zwischen unterschiedlichen Softwareumgebungen. Aus methodischer Sicht stellt die Entscheidung, auf bestehende Partnerschaften und proprietäre Technologien des Konzerns zurückzugreifen, einen pragmatischen Ansatz dar, der die technische Machbarkeit, die Datensicherheit und die langfristige Wartbarkeit der implementierten Infrastruktur sicherstellt. Zugleich verdeutlicht sie die Notwendigkeit, zukünftige Entwicklungen im Sinne einer offenen, interoperablen Systemlandschaft zu gestalten, um Abhängigkeiten von einzelnen Herstellern zu reduzieren und die Übertragbarkeit der entwickelten Architektur auf andere industrielle Kontexte zu gewährleisten.

Da die Umsetzung eines solchen Referenzmodells in einem industriellen *Brown-field*-Umfeld von zahlreichen externen Faktoren abhängt, wie bspw. der Verfügbarkeit von Netzwerkspezialisten, der Bereitstellung notwendiger Hardware und Software, den Budget- und Freigabeprozessen sowie den Restriktionen für netzwerkkritische Änderungen, wurde eine Ausweichstrategie für die Datenerfassung entwickelt. Diese Strategie sollte sicherstellen, dass die für das Modelltraining benötigten Sensordaten auch dann verfügbar sind, wenn infrastrukturelle Voraussetzungen oder Genehmigungen für eine direkte Cloud-Anbindung noch nicht vollständig vorliegen. Hierzu wurden die relevanten Prozess- und Zustandsdaten parallel auf einem tragbaren Speichermedium mitgeschrieben, sodass sie unabhängig von der Cloud-Integration unmittelbar für die Modellentwicklung zur Verfügung standen. Dieser Ansatz ermöglichte es, die Machine-Learning-Modelle bereits *on premise* zu entwickeln und zu trainieren, um sie anschließend in die Cloud-Umgebung zu überführen. Dadurch konnte die empirische Validierung der Fallstudien in der Mikroebene unabhängig von der physischen Infrastruktur vorbereitet und durchgeführt werden. Die Ausweichstrategie erwies sich somit als pragmatische Lösung zur Sicherstellung der Datenverfügbarkeit und als methodisches Bindeglied zwischen der konzeptionellen Planung des Referenzmodells und seiner praktischen Überprüfung.

Aufbauend auf den in den vorangegangenen Vorüberlegungen identifizierten technischen, organisatorischen und infrastrukturellen Rahmenbedingungen wurde zunächst eine konzeptionelle Architektur entwickelt, die die durchgängige Datenkette im Sinne der intelligenten Data Pipeline abbildet. Diese Darstellung ist bewusst zonenunabhängig konzipiert und beschreibt die logische Abfolge der Datenerfassung, -verarbeitung und -nutzung. Die Betrachtung reicht von der physischen Ebene der Produktion bis hin zur datenanalytischen Modellierung und Entscheidungsunterstützung in der Cloud. Ziel dieser Konzeption ist es, eine konsistente und übergreifende Sicht auf alle relevanten Datenflüsse zu schaffen, bevor im Rahmen der technischen Implementierung eine konkrete Einbettung in die bestehende IT- und OT-Infrastruktur erfolgt.

Die in **Abbildung 20** dargestellte Architektur visualisiert die durchgängige Kommu-

nikationskette zwischen den Produktionsanlagen, den vorgelagerten Datenerfassungssystemen und den Cloud-Diensten. Sie stellt den logischen Aufbau der Datenströme mit Nutzung von Komponenten der Siemens AG sowie der AWS dar, bei der Sensor-, Prozess- und Zustandsdaten aus der Fertigung zunächst lokal erfasst, anschließend auf Edge-Ebene vorverarbeitet und schließlich in cloudbasierten Umgebungen für weiterführende Datenanalysen und maschinelles Lernen genutzt werden [.] Dabei werden sowohl automatisierte maschinennahe Datenströme als auch potenziell anschlussfähige, domänenbezogene Informationsquellen, wie die Anlagendokumentationen, berücksichtigt, um die inhaltliche Vollständigkeit der Datenpipeline sicherzustellen.




Abbildung 20: Konzeptionelle Darstellung der Kommunikationskette

Den Ausgangspunkt der Datenkette bilden die Produktionsanlagen, an denen kontinuierlich Prozess-, Maschinen- und Zustandsdaten über Sensoren und Steuerungssysteme erfasst werden. Diese Sensordaten werden im CMS X-Tools gesammelt und dort einer ersten Datenvorverarbeitung unterzogen. Zu den grundlegenden Schritten zählen die Synchronisierung von Zeitstempeln, die Filterung von Störsignalen sowie die Aggregation relevanter Messgrößen. X-Tools fungiert damit als lokale Datensammel- und Integrationsschicht, die eine standardisierte Datenbasis für nachgelagerte Verarbeitungsschritte bereitstellt. Parallel dazu entsteht innerhalb der Instandhaltungsorganisation eine zweite, semantische Datenquelle in Form der Anlagendokumentation. Wie aus den Vorüberlegungen hervorgegangen, werden diese Informationen bislang manuell gepflegt. Darüber hinaus existiert keine automatisierte Schnittstelle, sodass der Grundgedanke eines konsistenten Datenflusses unterbrochen wird. Dennoch stellen sie einen zentralen Bestandteil des Referenzmodells in Form von domänenspezifischem Erfahrungswissen dar. Konzeptionell werden diese Dokumentationsdaten daher in der Architektur als potenziell integrierbare Wissensquelle berücksichtigt, deren Inhalte durch die Weiterentwicklung der BDE automatisiert bereitgestellt werden könnten. Die Einbeziehung dieser Datenebene dient der ganzheitlichen Betrachtung der Produktions- und Instandhaltungsprozesse und verdeutlicht das Potenzial einer späteren, hybriden Datenintegration. Die vorverarbeiteten Datensätze werden über einen standardisierten Kommunikationsdienst (**MQTT-Broker**) an eine Edge-Umgebung übertragen, die eine skalierbare Schnittstelle zwischen dem Produktionsnetz und der Cloud

bildet. Auf dieser Ebene erfolgt eine zusätzliche Datenaufbereitung, um die Datenformate, -frequenzen und -strukturen für nachgelagerte cloudbasierte Prozesse zu harmonisieren. Die Edge-Laufzeitumgebung (**Industrial Edge Runtime**) dient darüber hinaus als operative Plattform für die lokale Modellinferenz, sodass bereits trainierte Modelle direkt vor Ort auf Echtzeitdaten angewendet werden können, um auf Basis der eingehenden Echtzeitdaten Muster, Abweichungen oder Anomalien zu erkennen. Die in der Edge-Umgebung erzeugten und verarbeiteten Daten werden anschließend über das **Industrial Edge Management** in die Cloud überführt. Der Datentransfer und die Modellkommunikation erfolgen über **AWS IoT Greengrass**, das eine gesicherte Verbindung zwischen der lokalen Umgebung und den AWS-Diensten ermöglicht. Innerhalb der Cloud werden mittels **AWS-Services** die Daten persistent gespeichert, aufbereitet und zur Entwicklung und Validierung datenanalytischer Modelle genutzt. Nach erfolgreicher Modellbildung können die Modelle über den gleichen Kommunikationspfad wieder an die Edge-Ebene zurückgeführt und dort für die operative Analyse eingesetzt werden. Die Ergebnisse dieser Modelle, wie etwa Zustandssprognosen, Anomalieindikationen oder Handlungsempfehlungen, werden in einem Überwachungssystem visualisiert und den verantwortlichen Instandhaltungs- und Produktionsmitarbeitenden bereitgestellt. Diese Echtzeit-Visualisierung ermöglicht eine unmittelbare Rückkopplung zwischen datenanalytischen Erkenntnissen und operativen Entscheidungen. Perspektivisch kann dieser Rückkanal zudem durch die Integration der Wissensdaten aus den Anlagendokumentationen erweitert werden, sodass Handlungsempfehlungen mit historischem Erfahrungswissen angereichert und kontextualisiert werden können.

Die in der vorangegangenen **Abbildung 20** dargestellte Architektur bildet das konzeptionelle Zielbild einer durchgängigen Datenkette im Sinne der intelligenten Data Pipeline. Sie beschreibt den idealtypischen Informationsfluss von der physischen Datenerfassung über die lokale Vorverarbeitung bis hin zur cloudbasierten Modellierung und der anschließenden Rückführung datenanalytischer Modelle in den operativen Betrieb in Anbetracht der zuvor ermittelten Rahmenbedingungen. Dieses theoretische Architekturkonzept diene als methodische Grundlage für die nachfolgende technische Implementierung im realen Produktionsumfeld.

In Anlehnung an das forschungslogische Vorgehen des DSR sowie an die Struktur empirischer Fallstudien nach erfolgt nun die schrittweise Überführung des entworfenen Referenzmodells in die Praxis (vgl. **Kapitel 2.3, 2.5.2**). Der Implementierungsprozess verfolgt dabei das Ziel, die Realisierbarkeit und technische Anschlussfähigkeit der zuvor konzipierten Datenkette innerhalb der bestehenden IT- und OT-Infrastruktur des Presswerks zu überprüfen. Entsprechend wird im Folgenden dargelegt, welche Systemkomponenten physisch umgesetzt, welche prototypisch integriert und welche konzeptionell verbleiben mussten. Dabei zeigte sich, dass die Übertragung der theoretisch entwickelten Architektur auf eine bestehende Brownfield-Umgebung mit einer Reihe von praktischen Restriktionen verbunden war. Diese resultierten insbesondere aus infrastrukturellen Gegebenheiten, konzernweiten Sicherheitsvorgaben, eingeschränkten Zugriffsrechten auf produktive Systeme sowie der begrenzten Ressourcenverfügbarkeit. Dennoch konnten zentrale Elemente der intelligenten Data Pipeline exemplarisch in den operativen Betrieb integriert und unter realen

Betriebsbedingungen erprobt werden. Die in **Abbildung 21** dargestellte Struktur bildet die technisch realisierte Implementierung des Referenzmodells innerhalb der bestehenden IT- und OT-Infrastruktur des Presswerks ab. Sie folgt den zuvor konzipierten Grundprinzipien der intelligenten Data Pipeline und überführt diese in ein industriell umsetzbares Systemdesign. Die Implementierung steht dabei in enger methodischer und praktischer Verbindung zur Mikroebene der Fallstudien. Zum einen diente der Ziehkissen-Fall als leitendes Erprobungsszenario, um die Pipeline unter realen Betriebsbedingungen zu testen und die Funktionalität der Datenflüsse, Modellintegration und Ergebnisvisualisierung zu validieren. Zum anderen ermöglichte die gewählte Architektur eine parallele Datenerfassung für die Anwendungsfälle der Mikroebene, wodurch eine konsistente Datengrundlage für spätere Analysen geschaffen werden konnte.




Abbildung 21: Technisch realisierte Implementierung des Referenzmodells

Auf der untersten Ebene (Zone 4) befinden sich die Produktionsanlagen, in denen kontinuierlich Maschinen- und Prozessdaten generiert werden. Diese Daten bilden die Grundlage für alle weiteren Verarbeitungsschritte (**RME 1**). Die Funktion der Vorverarbeitung und Bereitstellung, wie sie im Referenzmodell als eigenständige Ebene (**RME 2**) konzipiert ist, wird im Anwendungskontext des Presswerks nicht als singulärer, zentralisierter Verarbeitungsschritt umgesetzt, sondern entlang der Datenkette gestuft und datenquellenabhängig realisiert. Diese Ausprägung ergibt sich aus der heterogenen Herkunft der Daten, den unterschiedlichen Automatisierungsgraden sowie der zonenbasierten Sicherheitsarchitektur der bestehenden IT- und OT-Infrastruktur. Über den in Zone 3 integrierten X-Tools-Server werden die Signale aus den Anlagen in hoher zeitlicher Auflösung erfasst, synchronisiert und zunächst lokal vorverarbeitet (s. **Anhang E Abbildung 58**). Diese initialen Schritte umfassen unter anderem die zeitliche Synchronisierung, Aggregation technischer Kennwerte sowie die Filterung von Störsignalen und dienen primär der Sicherstellung einer konsistenten und qualitätsgesicherten Datenbasis. In einem nachgelagerten Schritt erfolgt auf dem Industrial Edge eine weitere strukturelle Aufbereitung der Daten, um sie für den zonenübergreifenden Transfer und die Cloud-basierte Verarbeitung in einer geeigneten Form bereitzustellen. Innerhalb der Cloud-Umgebung werden die Daten schließlich so vorbereitet, dass

sie unmittelbar für die Modellierungs- und Trainingsprozesse nutzbar sind. Die Erhebung und Aufbereitung des Domänenwissens folgt hingegen einem abweichenden Automatisierungsgrad. Da diese Informationen überwiegend in unstrukturierter, dokumentenbasierter Form vorliegen, werden erste Vorverarbeitungsschritte lokal und manuell vorgenommen, etwa durch Sichtung, Selektion und grundlegende Strukturierung relevanter Inhalte. Nach der Überführung in die Cloud-Umgebung können diese Daten durch weiterführende Verarbeitungsschritte ergänzt und für die Informationsintegration sowie die wissensbasierte Kontextualisierung analytischer Ergebnisse nutzbar gemacht werden. Damit wird deutlich, dass sensorische Daten und Domänenwissen jeweils vorgelagert zur Informationsintegration erhoben und aufbereitet werden, bevor sie in der zentralen Integrationsschicht zusammengeführt werden. Die Vorverarbeitungsebene fungiert in diesem Kontext als funktionale Klammer über mehrere technisch verteilte Verarbeitungsschritte hinweg und bewahrt damit den abstrakten Charakter des Referenzmodells unter gleichzeitiger Berücksichtigung der realen infrastrukturellen Randbedingungen der industriellen Umgebung.

In Bezug auf die Sensordaten erfolgt über eine definierte Kommunikationsschnittstelle die Weiterleitung der verarbeiteten Daten an einen MQTT-Broker, der die strukturierte Weitergabe an nachgelagerte Systeme innerhalb der zonenübergreifenden Architektur übernimmt. In der ursprünglichen technischen Infrastruktur war an das CMS X-Tools ein OPC UA-Server angebunden, über den die Produktionsdaten der Anlagen für weiterführende Anwendungen bereitgestellt werden sollten. Im Verlauf der Implementierung zeigte sich jedoch, dass dieser Ansatz den Anforderungen an eine durchgängige und skalierbare Datenverarbeitung im Sinne der intelligenten Data Pipeline nicht hinreichend gerecht wurde.

Das Kommunikationsprotokoll OPC UA (*Open Platform Communications Unified Architecture*) ist zwar aufgrund seiner semantischen Informationsmodelle, standardisierten Schnittstellen und integrierten Sicherheitsmechanismen ein etablierter Standard in der industriellen Automatisierung [vgl. Ghotkar 2021, S.6477-6479]. Für stark verteilte Architekturen, die eine hohe Anzahl paralleler Datenpunkte verarbeiten, erwiesen sich jedoch die inhärenten Charakteristika des Client-Server-Prinzips als limitierend, insbesondere hinsichtlich der Latenz und Skalierbarkeit [vgl. Zunino et al. 2021, S. 5-8].

Vor diesem Hintergrund wurde entschieden, die Datenkommunikation zwischen X-Tools und den übergeordneten IT-Systemen auf das MQTT-Protokoll (*Message Queuing Telemetry Transport*) umzustellen. MQTT folgt einem Publisher-Subscriber-Modell, das auf einem zentralen Broker basiert und dadurch eine entkoppelte, asynchrone Kommunikation zwischen Datenquellen und -verbrauchern ermöglicht [vgl. Ferrari et al. 2018, S.2190]. Diese Architektur erlaubt es, auf spezifische Datenpunkte im X-Tools-System zu subscriben, wodurch nur relevante Informationen ereignisgesteuert übertragen werden. Dies reduziert die Netzwerklast erheblich und ermöglicht eine nahezu latenzfreie Bereitstellung von Sensordaten für nachgelagerte Edge-Anwendungen.

Die Entscheidung zugunsten von MQTT beruhte somit auf mehreren technischen und konzeptionellen Vorteilen. Dabei ermöglicht das Protokoll eine deutlich höhere Skalierbarkeit, da eine große Anzahl von Datenpunkten und Abonnenten über einen zentralen Broker effizient verwaltet werden kann [vgl. Jutadhamakorn et al. 2017, S.1-3]. Darüber hinaus

ist bietet MQTT eine schlanke Implementierung in das Netzwerk, was eine stabile und performante Integration in bestehende Edge-Architekturen begünstigt [vgl. Rausch et al. 2018, S.192-193]. Zudem bietet das asynchrone Kommunikationsprinzip eine bessere Entkopplung zwischen Erzeugern und Konsumenten, was die Robustheit des Gesamtsystems erhöht [vgl. Im und Lim 2023, S.1-5]. Schließlich ergeben sich auch sicherheitstechnische Vorteile im Kontext der industriellen Zonierung und Firewall-Segmentierung [vgl. M. Singh et al. 2015, S.747-749]. Im Gegensatz dazu weist OPC UA zwar eine stärkere semantische Integration auf, erfordert aber meist eine höhere Konfigurationskomplexität, eine engere Kopplung zwischen den Kommunikationspartnern und ist limitiert Kommunikationsleistung bei hoher Auslastung [vgl. Veichtlbauer et al. 2017, S.423-424; Morato et al. 2021, S.2-3; Muniraj und X. Xu 2021, S.53-54].

Auf Grundlage dieser Erkenntnisse wurde das Kommunikationskonzept angepasst. Der OPC UA-Server wurde durch einen MQTT-Broker ersetzt, der eine direkte Subscription auf ausgewählte Messpunkte aus X-Tools ermöglicht. Da X-Tools nativ keine MQTT-Schnittstelle bereitstellte, wurde diese Funktionalität in Kooperation mit dem Hersteller implementiert. Damit war es erstmals möglich, Sensordaten aus der Produktionsumgebung ereignisgesteuert an Edge-Systeme zu übertragen. Diese Anpassung stellte einen zentralen Schritt zur Realisierung einer skalierbaren, robusten und cloudfähigen Datenarchitektur dar, die die Grundlage für die Umsetzung und Evaluierung der intelligenten Data Pipeline im Rahmen der Mikrofallstudien bildet. Die konkrete Implementierung der Datentransferkette zwischen dem CMS X-Tools, dem MQTT-Broker und den auf der Industrial Edge ausgeführten datenanalytischen Modellen erfolgte in enger Zusammenarbeit mit den Industriepartnern Inpro mbH und der Siemens AG. Ziel war die Schaffung einer durchgängigen, standardisierten und bidirektional erweiterbaren Kommunikationsarchitektur, wobei der im System implementierte MQTT-Broker dabei als zentrale Verteilerinstanz dient, die es erlaubt, einzelne Topics gezielt zu abonnieren oder zu publizieren.

In dem betrachteten Fall wurden diese Topics zunächst in Abhängigkeit zu der Ziehkissen-Fallstudie thematisch gegliedert nach der Pressenposition, den Ist- und Soll-drücken der Verdrängereinheiten sowie den Werkzeugnummern (s. **Anhang E Abbildung 59**). Anschließend wurden die Datennachrichten im proprietären Siemens-JSON-Format publiziert und enthalten Zeit-Wert-Paare, die jeweils Datenpakete von rund zehn Sekunden abbilden (s. **Anhang E Abbildung 60**). Durch diese Struktur können hochfrequente Sensordaten ebenso wie niederfrequente Steuerdaten effizient verarbeitet werden, was insbesondere für die spätere Anomaliedetektion und Zustandsbewertung essenziell ist. Die über den Broker bereitgestellten Daten werden anschließend über einen MQTT-Client, der auf der Industrial Edge Management System ausgeführt wird, empfangen. Diese Komponente stellt das Bindeglied zwischen der operativen Datenerfassung und der analytischen Verarbeitung dar. Die datenanalytischen Modelle, deren konkrete Inhalte in **Kapitel 6.4** im Detail betrachtet werden, sind über die von der Inpro mbH entwickelte Applikation Data Elements auf dem Industrial Edge Management System installiert. Die auf dem Industrial Edge Management System installierten Applikationen sind der **Abbildung 61** im **Anhang E** aufgeführt (**RME 4**). Mittels der Applikation erfolgt die Modellinferenz direkt auf dem Industrial Edge IPC 487. Die im Rahmen der Modellinferenz auf dem

Industrial Edge erzeugten Analyseergebnisse werden anschließend über standardisierte Schnittstellen an das Überwachungssystem der intelligenten Data Pipeline übermittelt. Diese Übertragung umfasst sowohl numerische Modelloutputs, wie Zustandsindikatoren, Prognosewerte oder Anomaliescores, als auch kontextuelle Metadaten zur zeitlichen und anlagenbezogenen Einordnung der Ergebnisse. In der Überwachungsebene werden diese Informationen in Form von Dashboards und Visualisierungskomponenten aufbereitet und den relevanten Nutzergruppen bereitgestellt (**RME 5**). Die Überwachungsebene übernimmt dabei keine eigenständige Analysefunktion, sondern stellt die operative Sicht auf die Ergebnisse der Analyseebene dar und koppelt diese mit dem in der Wissensbasis abgelegten Erfahrungswissen. Auf diese Weise wird der Übergang von der datengetriebenen Analyse zur handlungsorientierten Entscheidungsunterstützung realisiert. Ein typisches Ausgabepaket eines Modells ist dabei wie in **Abbildung 62** im **Anhang E** aufgebaut. Zum Zeitpunkt der Implementierung waren primär die für die Ziehkissen-Fallstudie relevanten Topics aktiv. Dabei wurden die Daten mit der in X-Tools definierten Abtastfrequenz übertragen, während ergänzende Steuerinformationen mit geringerer Frequenz publiziert wurden.

Die Edge-Umgebung wird insgesamt zentral über das Industrial Edge Management-System administriert, das die Verteilung von Modellen, die Überwachung der Gerätezustände und das Management der Datenübertragung steuert. Über diese Management-Ebene besteht eine kontrollierte Verbindung sowohl innerhalb der Fabrikumgebung als auch in die Cloud-Infrastruktur der AWS, wo verschiedene AWS-Services genutzt wurden. Die in die Cloud-Ebene übermittelten Daten wurden zunächst in dem Simple Storage Service (S3) persistiert und anschließend in dem Analytik Service SageMaker für das Training und die Validierung von Machine Learning Modellen genutzt (**RME 7**). Ergänzend wurde im Rahmen der Ziehkissen-Fallstudie, ein webbasiertes Labeling Tool der Inpro mbH implementiert, über das Domänenexperten gewonnene Datensätze annotieren und so den Trainingsprozess unterstützen können (**RME 3**). Nach Abschluss des Trainingsprozesses werden die validierten Modelle verpackt und über das Industrial Edge Management System wieder an die Edge-Umgebung ausgerollt, wo sie für die Echtzeitanalyse verfügbar sind.

Darüber hinaus wurde neben dem Stream- parallel ein Batch-Datenfluss implementiert. Auf einem lokalen Hard-Disk-Drive (HDD) wurden die relevanten Produktionsdaten zusätzlich zwischengespeichert. Diese Speicherlösung ermöglicht die lokale Sicherung und redundante Ablage von Datensätzen, um sowohl eine spätere Cloud-Übertragung als auch eine unabhängige on-premise Datenanalyse zu gewährleisten. Diese parallele Speicherung war insbesondere für die Zahnstangenantrieb- und Druckluftgreifer-Fallstudien von zentraler Bedeutung, da hier keine vollständige Netzanbindung und Cloud-Kommunikation verfügbar war. Durch die redundante Speicherung konnten die Daten unmittelbar nach der Erfassung in einer isolierten Umgebung für explorative Analysen, Feature-Engineering und Modelltests genutzt werden. In Zone 2 wurde ergänzend das Domänenwissen in Form der anlagenbezogenen Dokumentationen in die Architektur integriert. Auch diese Datenquelle wird zusätzlich auf einem lokalen Speichermedium abgelegt und bildet die semantische Ergänzung zu den maschinellen Zustandsdaten. Zwar erfolgt derzeit keine automatisierte Anbindung dieser Dokumente, sie sind jedoch als potenziell anschlussfähige Wissensquelle

konzipiert, die perspektivisch über Natural-Language-Processing-Ansätze in die Pipeline integriert werden kann, um Erfahrungswissen der Instandhaltung systematisch zu nutzen. Erste Ansätze der Nutzung, wenn auch zunächst durch manuelle Sichtung der Dokumente, wurden in den Fallstudien der Mikroebene integriert.

Im Kontext der technischen Implementierung zeigte sich, dass die im Referenzmodell vorgesehene Wissensebene (**RME 6**) nur eingeschränkt realisiert werden konnte. Zwar wurde das Wissen über Instandhaltungsmaßnahmen, Stillstandsursachen und durchgeführte Eingriffe nachhaltig im bestehenden Betriebsdatenerfassungssystem abgelegt, eine technische Kopplung dieses Wissensbestands an das Überwachungssystem und die dort visualisierten Analyseergebnisse war jedoch nicht möglich. Damit blieb die Umsetzung hinter dem im Referenzmodell vorgesehenen Ziel einer integrierten Wissens- und Entscheidungsplattform zurück, in der domänenspezifisches Erfahrungswissen und datenanalytische Ergebnisse zusammengeführt und gemeinsam zur Entscheidungsunterstützung genutzt werden. In der vorliegenden Implementierung existieren beide Wissensströme, jedoch in getrennten Systemen. Gleichwohl stellt diese partielle Realisierung der Wissensebene einen wichtigen vorbereitenden Schritt dar. Durch die strukturierte und persistente Erfassung von Instandhaltungswissen wird eine Grundlage geschaffen, um datenanalytische Ergebnisse kausal zu interpretieren und in einen fachlichen Kontext einzuordnen. Auch ohne eine vollständige Systemintegration ermöglicht dieser Ansatz bereits eine kausal-prädiktive Nutzung der Analyseergebnisse und bildet damit eine notwendige Vorstufe für eine spätere Erweiterung hin zu präskriptiven Entscheidungsunterstützungssystemen. Das Referenzmodell adressiert diesen Zielzustand explizit, während die vorliegende Implementierung dessen schrittweise Annäherung unter realen infrastrukturellen Restriktionen demonstriert.

Insgesamt ermöglichte die implementierte Architektur eine stabile, latenzarme und zugleich skalierbare Datenübertragungskette, die sowohl den Anforderungen der Echtzeitverarbeitung als auch der Modellintegration in Cloud-Umgebungen gerecht wurde. Damit wurde eine zentrale technologische Grundlage geschaffen, um die intelligente Data Pipeline experimentell zu validieren und ihre Übertragbarkeit auf unterschiedliche industrielle Szenarien im Rahmen der Multifallstudie zu prüfen.

6.3.3 Zwischenfazit der Integration des Referenzmodells

Die Integration des entwickelten Referenzmodells in die bestehende technische Infrastruktur des betrachteten Presswerks verdeutlicht exemplarisch, wie sich die im theoretischen Konzept beschriebene intelligente Data Pipeline in einem industriellen *Brownfield*-Kontext realisieren lässt. Auf Grundlage der theoretischen Vorüberlegungen und der identifizierten infrastrukturellen Randbedingungen wurde eine durchgängige Datenarchitektur entworfen, die den Informationsfluss von der Anlagenebene über industrielle Edge-Systeme bis in eine Cloud-Umgebung abbildet. Damit wird das Referenzmodell nicht als starre Systemarchitektur, sondern als funktionaler Ordnungsrahmen umgesetzt, der sowohl operative Datenverarbeitung (OT) als auch übergeordnete IT-Strukturen integriert und miteinander koppelt.

Im Ergebnis konnte eine funktionale Datendurchgängigkeit über die relevanten Ebenen der Produktionsumgebung hinweg hergestellt werden. Durch die Einführung eines

MQTT-basierten Kommunikationskonzepts wurde eine stabile, latenzarme und skalierbare Datenübertragung realisiert, die die im Ausgangssystem identifizierten Limitierungen des OPC-UA-Ansatzes überwindet. Die Kopplung von X-Tools, Industrial Edge und Cloud-Services ermöglichte eine ereignisbasierte, strukturierte Bereitstellung von Maschinen- und Prozessdaten und schuf zugleich die Grundlage für die produktive Einbindung datenanalytischer Modelle. Damit konnte gezeigt werden, dass die im Referenzmodell formulierten funktionalen Ebenen – insbesondere Datenerhebung, Vorverarbeitung, Modellierung und Analyse – in einer realen Produktionsumgebung technisch getrennt, aber logisch konsistent umgesetzt werden können.

Die praktische Erprobung der integrierten Data Pipeline anhand der Ziehkissen-Fallstudie bestätigt darüber hinaus die grundsätzliche Funktionsfähigkeit des Referenzmodells im operativen Betrieb (vgl. **Kapitel 6.4**). Sensordaten wurden kontinuierlich erfasst, mehrstufig aufbereitet und datenanalytischen Modellen zugeführt, deren Ergebnisse wiederum in ein Überwachungssystem rückgespielt wurden. Gleichzeitig ermöglichte die ergänzende lokale Datenspeicherung die Entkopplung von Datenerfassung und Modellierung und schuf eine belastbare Grundlage für weitere Fallstudien. Die Architektur fungiert damit nicht nur als Implementierungsrahmen für einen einzelnen Anwendungsfall, sondern als generisches Trägersystem für unterschiedliche datenanalytische Szenarien innerhalb der Produktionsdomäne.

Gleichzeitig offenbarte die Integration des Referenzmodells eine Reihe struktureller Herausforderungen, die die Komplexität der Umsetzung intelligenter Data Pipelines im industriellen Umfeld verdeutlichen. Diese betreffen insbesondere die Heterogenität der Datenquellen, die sicherheitsbedingte Zonierung der IT- und OT-Infrastruktur sowie die organisatorischen Rahmenbedingungen der Wissensnutzung. Proprietäre Datenformate erforderten zusätzliche Harmonisierungsschritte, die strikte Netzsegmentierung begrenzte bidirektionale Rückkopplungsmechanismen, und die eingeschränkte Verfügbarkeit von Domänenexpertinnen und -experten wirkte sich auf Labeling- und Validierungsprozesse aus. Hinzu kommt die geringe Standardisierung textbasierter Wissensdokumente, die eine automatisierte Integration unstrukturierter Informationen erschwert und den Bedarf an semantischer Vorverarbeitung unterstreicht.

Ergänzend zeigte die Integration, dass die im Referenzmodell vorgesehene Wissensdatenbank in der praktischen Umsetzung nur eingeschränkt realisiert werden konnte. Zwar wurde instandhaltungsbezogenes Erfahrungswissen nachhaltig erfasst und strukturiert abgelegt, eine technische Zusammenführung dieses Wissens mit den Ergebnissen der datenanalytischen Modelle in einer gemeinsamen Entscheidungsunterstützungsplattform war jedoch nicht umsetzbar. Diese Abweichung vom idealtypischen Zielzustand des Referenzmodells ist nicht als methodisches Defizit zu interpretieren, sondern als explizite Implementierungsgrenze im industriellen Brownfield-Kontext. Das Referenzmodell beschreibt bewusst einen Zielzustand, dessen vollständige Ausschöpfung insbesondere für präskriptive Anwendungen eine enge Integration von Wissenshaltung und Analyseergebnissen voraussetzt. Die vorliegende Implementierung erfüllt diese Voraussetzung noch nicht vollständig, ermöglicht jedoch bereits eine kausal-prädiktive Nutzung der Analyseergebnisse und schafft damit die konzeptionelle Grundlage für eine spätere Erweiterung hin zu präskriptiven Entscheidungs-

ansätzen.

Insgesamt zeigt die Integrationsphase, dass eine intelligente Data Pipeline im industriellen **Brownfield** technisch realisierbar und funktional wirksam ist, sofern die infrastrukturellen, organisatorischen und semantischen Randbedingungen systematisch berücksichtigt werden. Zugleich verdeutlichen die identifizierten Limitationen den Bedarf an klar formulierten architektonischen, datenbezogenen und organisatorischen Anforderungen, die eine nachhaltige Skalierung und Weiterentwicklung ermöglichen. Die gewonnenen Erkenntnisse bilden damit die Grundlage für den nachfolgenden Abgleich zwischen den in **Kapitel 5** abgeleiteten Anforderungen und deren praktischer Umsetzung sowie für die weiterführenden Anwendungsfälle und die abschließende Bewertung des Referenzmodells.

6.4 Datenanalytische Anwendungsfälle

Aufbauend auf der in Kapitel 6.3 dargestellten Integration des Referenzmodells der intelligenten Data Pipeline in die bestehende Produktionsinfrastruktur erfolgt im Folgenden dessen exemplarische Anwendung auf konkrete technische Subsysteme der betrachteten Produktionsdomäne. Ziel dieses Kapitels ist es, die praktische Anwendbarkeit und Durchgängigkeit der implementierten Datenarchitektur anhand realer Produktionsdaten zu demonstrieren und damit die funktionale Tragfähigkeit des entwickelten Referenzmodells im industriellen Einsatz aufzuzeigen.

Hierzu werden drei datenanalytische Fallstudien betrachtet, die unterschiedliche technologische Komponenten einer Umformanlage repräsentieren: das Ziehkissen, der Zahnstangenantrieb sowie der Druckluftgreifer. Die Auswahl dieser Systeme erlaubt es, das Referenzmodell auf Anwendungsfälle mit jeweils unterschiedlichen funktionalen Eigenschaften, Datencharakteristika und Automatisierungsgraden zu übertragen und dessen Eignung zur Zustandsbewertung, Prozessanalyse und Anomalieerkennung zu untersuchen.

Das methodische Vorgehen der Analysen orientiert sich an etablierten Data-Mining-Prozessmodellen (vgl. **Kapitel 3.3.1**). Die Darstellung der Fallstudien werden dabei entlang der vier zentralen Phasen (1) Anwendungsverständnis, (2) Datenvorbereitung, (3) Modellierung und Ergebnisinterpretation sowie (4) Bereitstellung der Ergebnisse strukturiert. Diese Phasen sind nicht linear zu verstehen, sondern bilden einen iterativen Zyklus, in dem Erkenntnisse aus späteren Prozessschritten in frühere Phasen zurückfließen. Auf diese Weise wird gewährleistet, dass sowohl die technische Umsetzung als auch das inhaltliche Verständnis der Daten kontinuierlich verfeinert werden können.

Die Umsetzung der datenanalytischen Verfahren erfolgt unter Verwendung der Programmiersprache *Python*, die sich aufgrund ihres umfangreichen Ökosystems und ihrer industriellen Verbreitung als De-facto-Standard für datengetriebene Analysen etabliert hat [vgl. Johansson 2015, S.1–3; Srinath 2017, S.354–356]. *Python* bietet eine flexible und skalierbare Umgebung zur Verarbeitung großer Datenmengen, zur Merkmalsextraktion sowie zur Entwicklung und Validierung von Prognose- und Klassifikationsmodellen. Die Verwendung von *Python* gewährleistet zudem eine enge Verzahnung zwischen Datenvorverarbeitung, Analyse und Visualisierung, wodurch eine durchgängige und reproduzierbare Umsetzung der Analyseschritte innerhalb der intelligenten Data Pipeline ermöglicht wird. Dabei wird sowohl die technische Implementierung der Analyseprozesse als auch die methodische

Herangehensweise an die Datenaufbereitung, Feature-Generierung und Modellbildung beschrieben.

In den **Kapiteln 6.4.1 bis 6.4.3** werden die drei Fallstudien detailliert dargestellt und hinsichtlich ihrer Ergebnisse analysiert. Abschließend erfolgt in **Kapitel 6.4.4** eine querschnittliche Auswertung, in der die gewonnenen Erkenntnisse zusammengeführt, Gemeinsamkeiten herausgearbeitet und domänenübergreifende Schlussfolgerungen abgeleitet werden. Darüber hinaus werden die Ergebnisse kritisch reflektiert und in den Kontext der übergeordneten Forschungsziele eingeordnet.

6.4.1 Ziehkissen

Die nachfolgende Fallstudie verfolgt über die Beantwortung der Forschungsfragen hinaus das Ziel, die entwickelte intelligente Data Pipeline in einer realen Produktionsumgebung zu erproben und deren Leistungsfähigkeit exemplarisch zu validieren. Durch die Anwendung auf reale Prozessdaten wird überprüft, inwiefern die konzipierte Dateninfrastruktur die technische Grundlage für eine kontinuierliche Datenerfassung, -verarbeitung und -analyse im Produktionskontext bildet. Im Zentrum der Untersuchung steht die Analyse des dynamischen Verhaltens des Ziehkissens, das als wesentliches Funktionsmodul der Umformpresse den Materialfluss während des Tiefziehprozesses steuert. Durch den Einsatz der implementierten Data Pipeline und den gezielten Einsatz von Datenanalyseverfahren werden Muster, Abweichungen und Einflussfaktoren im Prozessverlauf identifiziert, um daraus Erkenntnisse über Betriebszustände und Optimierungspotenziale abzuleiten. Dabei wurde die wissenschaftliche Konzeption der Analyse, einschließlich Problemformulierung, Merkmalsauswahl, methodische Modellentscheidung, die Interpretation der Ergebnisse sowie die Beschlüsse über die Integrationsschritte im Kontext des Referenzmodells, durch den Autor vorgenommen. Die praktische Umsetzung der algorithmischen Ansätze erfolgte in enger Zusammenarbeit mit dem Industriepartner inpro mbH. In diesem Rahmen wurde ein speziell auf den betrachteten Anwendungsfall zugeschnittenes Analysetool konzipiert, integriert und getestet. Die Unterstützung durch inpro mbH umfasste insbesondere die operative Umsetzung des Feature Engineerings, die Nutzung einer proprietären Labeling-Plattform, die Durchführung von Trainings- und Testläufen sowie das technische Deployment der Modelle innerhalb der Industrial-Edge- und Cloud-Umgebung. Das entwickelte Verfahren wurde zum Patent angemeldet, was die Neuartigkeit und industrielle Relevanz der Lösung unterstreicht (vgl. **Anhang D**).

(1)Anwendungsverständnis. Das Ziehkissen stellt innerhalb der betrachteten Umformanlage ein zentrales Subsystem dar, das den Materialfluss während des Tiefziehprozesses maßgeblich beeinflusst. Es dient dazu, über den Niederhalter eine geregelte Gegenkraft auf das Blech auszuüben, um den Werkstofffluss aus dem Flanschbereich zu steuern und Faltenbildung während des Umformvorgangs zu vermeiden. Die resultierende Kraftwirkung muss dabei so gestaltet sein, dass ein gleichmäßiger Waddickenverlauf im Bauteil erzielt wird, ohne dass es zu lokalen Überdehnungen oder Rissen kommt. Im betrachteten Anwendungskontext handelt es sich um ein hydraulisch betriebenes Mehrpunkt-Ziehkissen, das mit acht einzeln regelbaren Verdrängerzylindern ausgestattet ist (vgl. **Abbildung 22**).

Diese Konfiguration ermöglicht es, die auf den Niederhalter wirkenden Kräfte räumlich differenziert einzustellen und somit komplexe Bauteilgeometrien abzubilden. Die Regelung der Ziehkissenkräfte erfolgt dabei in Abhängigkeit von der Pressenlinieneinstellung über ein elektronisches Steuersystem, das die Zielkräfte für jeden Zylinder dynamisch vorgibt. Die für die Ziehkissen-Fallstudie benötigten Sensorwerte sind der Verdränger Ist sowie Solldruck für alle Verdrängerzylinder, die Werkzeugnummer, die Pressenposition und der Zeitstempel.




Abbildung 22: Schematische Anordnung Verdrängerzylinder

Zum Wissensaufbau in Bezug auf das Regelungsverhalten des Ziehkissens wurde mit dem in **Kapitel 6.2.2** vorgestellten Prozessanalyseteam das in **Abbildung 23** gezeigte Schaubild vertieft. Grundlage bildeten Erfahrungswerte aus realen Produktionszyklen, experimentelle Messungen sowie die Auswertung historischer Prozessdaten der betrachteten Umformanlage. Die in der Darstellung verwendeten Grenz- und Toleranzwerte wurden auf Basis dieser Experteneinschätzungen definiert und anschließend zur Validierung der in der Fallstudie eingesetzten Datenmodelle herangezogen. Das dynamische Verhalten des Ziehkissens wird durch die Regelung des hydraulischen Antriebs bestimmt, welche die Sollkraft über den gesamten Umformhub möglichst konstant hält. Ziel ist es, Druckabweichungen und Schwingungen während des Pressvorgangs zu minimieren, um eine gleichmäßige Materialverteilung sicherzustellen. Dabei lassen sich die charakteristischen Kenngrößen wie folgt beschreiben:

- **Kraftaufbauweg:** Strecke, über die die Sollkraft erreicht wird (typisch max. 15 mm).
- **Überschwingen:** kurzfristiges Überschreiten der Sollkraft infolge des hydraulischen Trägheitsverhaltens (max. 500 kN).
- **Unterschwingen:** nachfolgende Gegenbewegung unterhalb der Sollkraft (max. 300 kN).
- **Restwelligkeit:** verbleibende kleine Schwingungen im stationären Bereich.
- **Sollkrafttoleranz:** zulässige Abweichung der Ziehkissenkraft von der Zielkraft ($\pm 5\%$).

Diese Parameter dienen als Indikatoren für die Regelgüte und spiegeln die mechanische und hydraulische Dynamik des Systems wider. Eine zu große Restwelligkeit oder ein ver-

zögerter Kraftaufbau kann unmittelbar die Bauteilqualität beeinflussen, da das Ziehkissen maßgeblich die Materialflussbedingungen während des Tiefziehvorgangs bestimmt. Des Weiteren sind diese Informationen notwendig für den weiteren Data-Mining-Prozess.




Abbildung 23: Kenngrößen des Regelungsverhaltens eines Ziehkissens

(2) Datenvorbereitung. Die Datengrundlage der Fallstudie umfasst kontinuierlich aufgezeichnete Prozessdaten des Ziehkissens der betrachteten Pressenlinie im Zeitraum von März 2019 bis September 2022. Die vom Ziehkissen erzeugten Kraftverläufe sowie zugehörige Zustandsgrößen wurden fortlaufend über das CMS X-Tools erfasst und lokal auf HDDs gespeichert. Dabei besitzen die aufgenommenen Variablen die in **Tabelle 10** aufgeführten Sensornamen, Beschreibungen und Datentypen. Wie in **Abbildung 22** dargestellt, werden neben dem Ist- auch der Solldruck der jeweiligen Verdrängerventile sowie Hilfsgrößen wie der Zeitstempel, die Pressenposition und die Werkzeugnummer aufgezeichnet. Da in der betrachteten Anlagenumgebung keine automatisierte Cloud-Anbindung implementiert war, erfolgte die Datenübertragung nach Befüllung der jeweiligen HDDs manuell. Hierzu wurden die vollständigen Datensätze nachträglich in die in **Kapitel 6.3** beschriebene Cloudlösung überführt, um die dort implementierten AWS-Services zur Datenaufbereitung, zum Labeling und zur Modellierung nutzen zu können. Auf diese Weise konnte trotz der beschränkten Infrastruktur eine durchgängige Verarbeitungskette gemäß der intelligenten Data Pipeline realisiert werden. Eine mögliche Umsetzung der Speicherlösung direkt auf dem Industrial Edge wurde zwar in Erwägung gezogen, allerdings aufgrund der zu geringen Speicherkapazität für ein lokales Speichern verworfen. Parallel zur Datenerfassung wurden die Anlagen- und Werkstattbücher kontinuierlich herangezogen, um Kontextinformationen über Prozessabweichungen, Wartungsereignisse oder Einstellungsänderungen zu gewinnen. Da auf diese Dokumentationen kein automatisierter Zugriff bestand, erfolgte die Auswertung manuell, indem bei Bedarf relevante Einträge auf einer lokalen HDD gesichert und mithilfe von Microsoft Excel analysiert wurden. Diese Vorgehensweise diente der gezielten Extraktion von Domänenwissen, das als qualitative Ergänzung zu den Sensordaten herangezogen wurde. Durch die Kombination beider Informationsquellen konnte ein umfassendes Verständnis des Systemverhaltens geschaffen werden, das die Grundlage für die

nachfolgende datengetriebene Analyse bildet.

Tabelle 10: Übersicht Sensorsignale Ziehkissen-Fallstudie

Sensorname	Beschreibung	Datentyp
Zeitstempel	Tag und Zeit des Sensorwerts	string
Verdränger Istdruck [1–8]	Istdruck an den Verdrängerventilen 1 bis 8	integer
Verdränger Solldruck [1–8]	Eingestellter Solldruck an den Verdrängerventilen 1 bis 8	integer
Pressenposition	Kurbelwellenposition [°]	integer
Werkzeugnummer	Nummer des eingesetzten Werkzeugs	integer

Im Anschluss an die Datenerfassung erfolgte die eigentliche Datenvorbereitung im Sinne des klassischen ETL-Prozesses. Zunächst wurden alle fehlerhaften, unvollständigen oder physikalisch unplausiblen Messwerte identifiziert und entfernt. Im nächsten Schritt erfolgte die Transformation der Daten. Die einzelnen Sensorkanäle der Verdränger wurden mit den entsprechenden Zeitstempeln und Pressenpositionsdaten verknüpft, sodass sich ein vollständiger zeitlicher Kraftverlauf pro Pressenzyklus abbilden ließ. Ein Zyklus entspricht dabei einer Kurbelwellenumdrehung von 360° , wodurch sich für jeden Verdränger ein charakteristischer Druckverlauf über den gesamten Hub ergibt. Zur Reduktion des Datenvolumens und zur Glättung hochfrequenter Signalanteile wurde die ursprüngliche Abtastrate von 100 Hz auf 10 Hz reduziert. Diese Frequenz erwies sich als ausreichend, um die relevanten Dynamiken des Ziehkissenverhaltens präzise abzubilden, gleichzeitig aber eine performante Verarbeitung innerhalb der Cloud-Umgebung zu gewährleisten. Anschließend wurden alle Druckwerte zur Vergleichbarkeit zwischen den einzelnen Verdrängerzylindern und Werkzeugkonfigurationen normiert, sodass die resultierenden Zeitreihen unabhängig von absoluten Druckniveaus ausgewertet werden konnten. Die resultierenden Zeitreihen wurden darauf folgend zur weiteren Analyse zusammengeführt und visualisiert.




Abbildung 24: Exemplarische Druckverläufe der Verdränger

Die **Abbildung 24** zeigt exemplarisch die aufgezeichneten Druckverläufe der acht Verdrängerzylinder des Ziehkissens über einen vollständigen Pressenzyklus. Jeder Zyklus entspricht einer Umdrehung der Kurbelwelle über 360° , wodurch sich für jeden Verdränger ein charakteristischer Druckverlauf in Abhängigkeit der Pressenposition ergibt. Zu Beginn

des Zyklus ist der Druck in allen Zylindern auf einem nahezu konstanten, niedrigen Niveau, was der Phase des Werkzeugöffnens entspricht. Mit zunehmender Kurbelwellenstellung erfolgt der Druckaufbau, der den Niederhalter mit der erforderlichen Haltekraft beaufschlagt. Sobald der maximale Kraftaufbau erreicht ist, wird dieser während des Tiefziehvorgangs aufrechterhalten, bevor gegen Ende des Zyklus der Druck wieder kontrolliert abfällt. Die dargestellten Verläufe zeigen ein weitgehend synchrones Verhalten der acht Verdränger, was auf eine gleichmäßige Krafteinleitung über die gesamte Auflagefläche des Niederhalters schließen lässt. In Abstimmung mit dem in **Kapitel 6.2.2** vorgestellten Prozessanalyse-Team können kleinere Abweichungen im Maximaldruck und im Verlauf der Druckrampen auf systembedingte Unterschiede in der Hydraulik oder auf lokale Reibungseinflüsse innerhalb der einzelnen Verdrängereinheiten hin deuten. Solche Differenzen können sowohl durch geringfügige Unterschiede im Ventilzustand als auch durch Temperatur- und Viskositätseffekte des Hydrauliköls erklärt werden. Die beobachteten Druckplateaus im oberen Bereich verdeutlichen, dass der Sollwert während der aktiven Umformphase stabil gehalten wird, während die abrupten Druckabfälle am Zyklusende den Übergang in die Rückhubphase markieren. Insgesamt weist der beobachtete Druckverlauf ein prozessphysikalisch plausibles Verhalten auf, das die erwartete Funktionsweise des Zieh kissens widerspiegelt. Folglich kann der Kurvenverlauf entsprechend der **Abbildung 25** in verschiedene Bereiche eingeteilt werden, die in der späteren Merkmalsauswahl in der Modellierungsphase betrachtet werden.




Abbildung 25: Festgelegte Kurvenbereiche des Verdrängerdrucks

(3) Modellierung und Ergebnisinterpretation. Auf Grundlage der zuvor beschriebenen Datenbasis und der Analyse der exemplarischen Druckverläufe werden im Folgenden datengetriebene Modelle zur Charakterisierung und Bewertung des Zieh kissens

entwickelt. Ziel ist es, die in den Zeitreihen enthaltenen Informationen so aufzubereiten, so dass sie das physikalische Verhalten des Systems adäquat abbilden. Die zuvor gewonnenen Erkenntnisse aus den **Abbildungen 23** und **24** dienen dabei als konzeptionelle Grundlage für das anschließende Feature Engineering. Im Anschluss an die Datenaufbereitung erfolgte die systematische Ableitung relevanter Merkmale (*Features*) aus den normierten Zeitreihen der Verdrängerdruckverläufe. Dieser Schritt bildet die Brücke zwischen der physikalischen Beschreibung des Ziehkissenverhaltens und der datengetriebenen Modellbildung. Die Vorgehensweise orientierte sich am in **Kapitel 6.3** beschriebenen Referenzmodell der intelligenten Data Pipeline und am gemeinsam im Kontext des Forschungsvorhabens mit der inpro mbH definierten Struktur. Ziel des Feature Engineerings war es, aus den kontinuierlichen Druckverläufen Merkmale zu extrahieren, die das Regel- und Prozessverhalten des Ziehkissens quantitativ beschreiben. Dazu wurde der in **Abbildung 25** in logisch abgegrenzte Phasen unterteilte Druckverlauf mit den herangezogen. Innerhalb dieser Bereiche wurden charakteristische statistische, spektrale und ableitungsbasierte Größen berechnet, um sowohl stationäre als auch transiente Effekte zu erfassen. Darüber hinaus erfolgte die Merkmalsbildung in der folgenden Strukturierung:

1. **Kenngößen erster Ordnung** – Merkmale einzelner Pressenzyklen, wie maximale und minimale Druckwerte, Druckgradienten, Abweichung vom Sollwert sowie Frequenzanteile aus der schnellen Fourier-Transformation (FFT).
2. **Kenngößen zweiter Ordnung** – Zyklusübergreifende Merkmale, die Schwankungen und Driftverhalten beschreiben, etwa Varianz und Mittelwert der Maximaldrücke über mehrere Zyklen oder interzyklische Abweichungen im Frequenzraum.
3. **Kenngößen dritter Ordnung** – Korrelationen und Beziehungen zwischen zuvor berechneten KPIs sowie zwischen verschiedenen Sensoren, die zur Ableitung höherwertiger Zustandsindikatoren genutzt werden können.

Die auf diese Weise berechneten 52 Schlüsselindikatoren bilden die Grundlage für die nachfolgenden Lernverfahren. Sie ermöglichen es, sowohl kurzfristige Regelabweichungen als auch langfristige Veränderungen im Systemverhalten zu erfassen. Darüber hinaus gestattet diese Merkmalsextraktion eine physikalisch interpretierbare Rückführung der späteren Modellresultate auf reale Prozesszustände des Ziehkissens. Das in **Abbildung 26** exemplarisch aufgeführte Merkmal zeigt die Abweichung der normierten Druckverläufe vom Mittelwert über einen Zeitraum von mehr als 500 Pressenzyklen für ein Werkzeug. Dargestellt ist die Differenz der jeweiligen Druckwerte zu ihrem mittleren Verlauf über die gesamte Kurbelwellenumdrehung von 360° für alle acht Verdrängerzylinder des Ziehkissens. Auf diese Weise wird sichtbar, in welchen Phasen des Pressenzyklus wiederkehrende systematische Abweichungen oder zufällige Schwankungen auftreten. In den dargestellten Heatmaps lässt sich erkennen, dass der Druckverlauf insbesondere im Bereich des Kraftaufbaus und des Druckplateaus zyklisch stabil bleibt, während in der Druckabbauphase sowie an den Übergängen zwischen den Phasen höhere Varianzen auftreten. Diese Abweichungen deuten auf unterschiedliche hydraulische Reaktionszeiten und minimale Schaltverzögerungen der Ventile hin, die im Rahmen der späteren Modellbildung als potenzielle Indikatoren

für Regelungsabweichungen berücksichtigt werden können. Darüber hinaus zeigen einzelne Verdränger (z. B. V2 und V3) ein leicht abweichendes Verhalten über die Zyklen hinweg, was auf lokale Effekte wie Ventilcharakteristik oder unterschiedliche Belastungssituationen schließen lässt. In der Systematik wurden sämtliche Merkmale betrachtet, deren inhaltliche Ausführung in dieser Arbeit nicht forciert wird, da sie keinen expliziten Beitrag zur Beantwortung der Forschungsfragen hinsichtlich der Implementierung beiträgt.




Abbildung 26: Abweichung der Druckverläufe vom Mittelwert über mehrere Zyklen

Die Modellierung erfolgte auf Grundlage der in **Kapitel 5.8** beschriebenen Merkmale unter Nutzung des von im Gemeinschaftsprojek mit der inpro mbH entwickelten *inAI-Toolkits* für Zeitreihendaten, dessen Funktionalität das Labeln, die Modellierung sowie die Bereitstellung umfasst. Das Ziel bestand darin, ein datengetriebenes Modell zur Zustandsbewertung und Anomaliedetektion des Ziehkissens zu entwickeln, das im Rahmen der intelligenten Data Pipeline automatisiert trainiert, validiert und ausgerollt werden kann. Das zugrundeliegende Systemdesign folgt dem Prinzip, das im *inAI-Toolkit* ein kontinuierlicher Datenfluss zwischen den Prozessdaten, den Labeling-Ergebnissen und den trainierten Modellen realisiert wurde. Hierzu wird ein zentraler Speicherort innerhalb der Cloudumgebung, gemäß der in **Kapitel 6.3.2** vorgestellten technischen Implementierung, als strukturierte Datendrehscheibe eingesetzt, in dem sowohl Rohdaten, annotierte Zeitreihen aus dem Labeling-Tool als auch die Resultate der trainierten Modelle gespeichert und verwaltet werden. Diese Datenhaltung erfolgt in Form einer standardisierten JSON-Struktur, die Zeitstempel, Label, Messwerte und Modellparameter in einheitlicher Form abbildet. Durch die Integration dieser Datenarchitektur in die in **Kapitel 6.3** beschriebene Cloud-Umgebung wurde eine durchgängige Verarbeitungskette geschaffen, die das Einlesen, Transformieren, Labeln, Trainieren und Ausrollen der Modelle in der Ebene der Cloud der intelligenten Data Pipeline ermöglicht. Diese Architektur bildet die Grundlage für den im weiteren Verlauf beschriebenen cloudbasierten Rollout und die kontinuierliche Modellaktualisierung innerhalb der Produktionsumgebung.

Eine zentrale Komponente für das Training bildeten gelabelte Zeitreihen, die mithilfe des *inAI Labeling Tools* aus dem *inAI-Toolkit* erstellt wurden. Das Labeling erfolgte

vollständig manuell und stellte einen der zeitintensivsten Schritte innerhalb der Modellentwicklung dar, da für jedes Sensorsignal die relevanten Zeiträume mit normalem und abweichendem Prozessverhalten händisch markiert werden mussten. Das Tool dient der visuellen Aufbereitung und Annotation von Zeitreihen und erlaubt es, Anomalien oder charakteristische Signalabschnitte durch direkte Interaktion mit dem Diagramm zu kennzeichnen. Nach Auswahl des zu untersuchenden Objektes sowie des entsprechenden Sensors konnte über eine Kalendermenüleiste der zu analysierende Zeitraum definiert und die Daten in die Benutzeroberfläche geladen werden. Anschließend wurden die Zeitreihen in einem Diagramm angezeigt, wobei über eine *Kontextleiste* eine grobe Bereichsauswahl und über eine *Detaillleiste* eine präzise Feineinstellung vorgenommen werden konnte. Das Labeln selbst erfolgte durch Klicken und Ziehen mit der Maus über die interessierenden Bereiche oder durch selektives Anklicken einzelner Datenpunkte. Markierte Zeitpunkte wurden farblich hervorgehoben, um sie visuell von den restlichen Daten zu unterscheiden. Über die Menüleiste ließen sich sämtliche aktuell gesetzten Labels löschen oder die bearbeiteten Zeitreihen als komprimierte Datei exportieren. Der Export erzeugte eine *.csv*- bzw. *.json.gz*-Datei, die den Zeitstempel, das Label und den zugehörigen Messwert enthielt. Diese Dateien wurden in den Speicher-Service (S3) der Cloud-Umgebung hochgeladen und dienten als Eingabedaten für den *inAI Model Trainer* aus dem *inAI-Toolkit*. Dadurch konnten die manuell erzeugten Labels direkt in die nachfolgenden Machine-Learning-Prozesse integriert werden. Da eine automatisierte Labelgenerierung im betrachteten Zeitraum nicht verfügbar war, mussten sämtliche relevanten Signale einzeln begutachtet und markiert werden. Ein zusätzlicher Aufwand entstand, weil Domänenexperten aus der Instandhaltung oder Prozessanalyse nicht immer unmittelbar zur Verfügung standen. Um die Labelqualität sicherzustellen, wurden daher parallel die Anlagen- und Werkstattbücher intensiv ausgewertet, um auftretende Ereignisse (z. B. Ventilwechsel, Druckabweichungen, Stillstände) zeitlich korrekt den aufgezeichneten Sensordaten zuordnen zu können. So wurde sichergestellt, dass die manuell gesetzten Labels eine technisch und prozessual fundierte Abbildung des tatsächlichen Anlagenzustands darstellten. Die so erzeugten gelabelten Zeitreihen bildeten die Trainings- und Validierungsbasis für die im nächsten Schritt trainierten Modelle.

Für die Zustandsklassifikation des Ziehkissens wurde ein *Random Forest Classifier* implementiert, der sich im Forschungsvorhaben als das leistungsfähigste Verfahren zur Erkennung von Regelabweichungen erwiesen hat (vgl. **Kapitel 3.3.3**). Das Training erfolgte innerhalb des *inAI-Model Trainer* aus dem *inAI-Toolkit*, der im Rahmen des Toolkits eine vollständige Prozesskette von der Datenaufnahme bis zum validierten ML-Modell bereitstellt. Als Eingangsdaten dienten die in der Datenvorbereitungsphase erstellten zeitlich synchronisierten und normierten Zeitreihen mit den ergänzenden gelabelten Daten, die im S3 gespeichert waren. Die zweistufige Modellarchitektur folgt einem sequenziellen Ansatz, bei dem zunächst relevante Merkmale aus den Zyklusdaten extrahiert und anschließend zur Klassifikation herangezogen werden. In der ersten Stufe erfolgte die Berechnung charakteristischer Kennwerte, die die physikalischen und regelungstechnischen Eigenschaften des Ziehkissens abbilden. Diese Merkmale, wie sie zuvor im Kontext des Feature Engineerings beschrieben wurden, bildeten die Eingangsdaten für die nachgelagerte Klassifikationsstufe, in der das Modell die Zuordnung der Prozesszustände zu den definierten

Klassen vornahm. Diese Merkmale wurden über definierte Winkelbereiche des Pressenhubes ($t_{\min} = 0^\circ$, $t_{\max} = 359.9^\circ$) hinweg gebildet und anschließend mit dem Werkzeug-Metadatum verknüpft. Die *targetNormalization*-Funktion normalisierte den Ist-Druck auf Basis des Soll-Drucks, und der Filter *selectAreas* zerlegte das Signal in die zuvor festgelegten Funktionsbereiche des Kurvenverlaufs. Darauf folgend wurde das Training des Modells im AWS-Service SageMaker durchgeführt, indem die Trainings- und Testdatenquellen, der zeitliche Gültigkeitsbereich sowie die Label-Zuweisungen konfiguriert wurden. Dabei erfolgte die Spezifikation von Datenmengen, Zeitfenster, Label („0 = i. O.“ / „1 = n. i. O.“) und das Verhältnis der Trainings- und Testdaten von 80 zu 20. Nach erfolgreicher Konfiguration wurde die einzelnen Prozesse bis hin zur Ergebnisvalidierung automatisiert durchgeführt. Die Hyperparameter folgten dabei der Standardkonfiguration von $n\_estimators = 100$ und $n\_jobs = 1$. Das Training verwendete sowohl i. O.- als auch n. i. O.-Sequenzen, um eine robuste Entscheidungsgrenze zwischen den Zuständen zu erlernen. Eine exemplarische Konfusionsmatrix für 1.000 Zyklen ist in **Abbildung 27** dargestellt.

Tatsächlicher Wert []	Errechneter Wert []	
	0	1
0	702	32
1	68	198

Abbildung 27: Exemplarische Konfusionsmatrix für 1000 Zyklen

Die Konfusionsmatrix zeigt die Ergebnisse der Klassifikation des trainierten Random-Forest-Modells für die Zustandsbewertung des Ziehkissens. Sie stellt die tatsächlichen Zustände den vom Modell vorhergesagten Klassen gegenüber und ermöglicht somit eine Bewertung der Klassifikationsgüte anhand von True-Positive-, True-Negative-, False-Positive- und False-Negative-Ergebnissen. Von insgesamt 1000 ausgewerteten Pressenzyklen wurden 702 Zyklen korrekt als fehlerfrei (*i. O.*) klassifiziert und 198 Zyklen zutreffend als fehlerhaft (*n. i. O.*) erkannt. Demgegenüber stehen 32 *False Positives*, also fälschlicherweise als fehlerhaft erkannte Zyklen, sowie 68 *False Negatives*, bei denen tatsächliche Abweichungen nicht detektiert wurden.

Aus diesen Werten lassen sich die zentralen Leistungskennzahlen des Modells wie folgt berechnen:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{198 + 702}{1000} = 0.90$$

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{198}{198 + 32} = 0.86$$

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{198}{198 + 68} = 0.74$$

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \approx 0.80$$

Das Modell erreicht damit eine Gesamtgenauigkeit von 90 % bei einer Präzision von 86 %. Die Sensitivität (Recall) liegt mit 74 % unterhalb der Präzision und zeigt, dass ein Teil der fehlerhaften Zyklen noch nicht zuverlässig erkannt wird. Dies lässt sich darauf zurückführen, dass einige Regelabweichungen aufgrund geringfügiger Druckdifferenzen oder unvollständig gelabelter Trainingsdaten im Modell nicht eindeutig abgebildet sind. Die Fehlalarmrate bleibt mit lediglich 3,2 % (32 von 1000 Fällen) jedoch niedrig, was auf eine robuste Klassifikationsleistung hinweist. Insgesamt zeigt die Konfusionsmatrix, dass das trainierte Random-Forest-Modell in der Lage ist, den Zustand des Ziehkissens mit hoher Genauigkeit zu bewerten. Es unterscheidet zuverlässig zwischen fehlerfreien und fehlerhaften Prozesszuständen und liefert damit eine belastbare Grundlage für die Integration in die intelligente Data Pipeline.

Die **Abbildung 28** zeigt exemplarisch die modellbasierte Zustandsbewertung des Verdrängers 1 über einen längeren Beobachtungszeitraum. Im oberen Diagramm sind die vom trainierten Random-Forest-Modell berechneten Zustandswahrscheinlichkeiten dargestellt, während das untere Diagramm die daraus abgeleitete Klassifikation in die Zustandskategorien *i. O.* (gut) und *n. i. O.* (schlecht) zeigt. Die binäre Zustandslogik basiert auf einer Entscheidungsgrenze von 0,5, oberhalb derer der Zyklus als fehlerhaft eingestuft wird. Zu Beginn des Beobachtungszeitraums bis etwa Mitte 2019 liegt eine stabile Phase mit überwiegend *i. O.*-Klassifikationen vor, die auf einen regelkonformen Betrieb des Verdrängers hindeutet. Ab etwa August 2019 zeigt das Modell eine zunehmende Streuung der Zustandswahrscheinlichkeiten und eine Häufung von *n. i. O.*-Ergebnissen. Diese Übergangsphase fällt zeitlich mit in den Anlagen- und Werkstattbüchern dokumentierten Anpassungen am Hydrauliksystem zusammen, wodurch das Modellverhalten plausibel erklärbar wird. Der darauf folgende Zeitraum (September bis Oktober 2019) ist durch eine klare Zunahme an negativen Klassifikationen geprägt, was auf eine Verschlechterung des technischen Zustands des Verdrängers hinweist. Das Modell detektiert hier wiederkehrende Anomalien im Druckverlauf, die auf einen fortschreitenden Verschleiß oder Undichtigkeiten im Ventilsystem schließen lassen. Nach der in den Werkstattbüchern vermerkten Wartungsmaßnahme stabilisiert sich der Zustand wieder, was an der Reduktion der *n. i. O.*-Ergebnisse erkennbar ist. Diese exemplarische Darstellung verdeutlicht, dass das trainierte Modell in der Lage ist, zeitliche Veränderungen des Anlagenzustands zuverlässig zu erfassen und in einen technisch interpretierbaren Kontext zu setzen. Die enge Übereinstimmung mit den dokumentierten Wartungs- und Einstellvorgängen belegt die Praxistauglichkeit des entwickelten Ansatzes zur kontinuierlichen Zustandsüberwachung.

(4) Bereitstellung. Das in **Abbildung 29** dargestellte Schaubild veranschaulicht die funktionale Einbettung der Modellierung in die Gesamtsystematik der intelligenten Data Pipeline. Der linke Teil der Abbildung beschreibt den Cloud-basierten Abschnitt, in dem die Datengrundlage für das Modelltraining bereitgestellt, aufbereitet und verarbeitet wird. Hierzu werden die über die Data Pipeline erfassten und manuell gelabelten Zeitreihen aus




Abbildung 28: Exemplarische Zustandsaussage für Verdränger 1

der Produktionsumgebung in den Cloud-Speicher (AWS-Service S3) überführt. Innerhalb der Cloud-Umgebung erfolgt anschließend das Training der Modelle unter Verwendung des AWS-Services SageMaker. Die für das Training erforderlichen Eingabedaten werden über die S3-Schnittstelle automatisiert an den Trainingsservice übergeben. Das Ergebnis dieses Prozesses ist ein validiertes Modellartefakt sowie der zugehörige Deployment-Code, die in der Cloud-Umgebung versioniert und für den nachfolgenden Rollout bereitgestellt werden. Der rechte Teil der Abbildung beschreibt die nachgelagerte Bereitstellung (*Model Deployment*) innerhalb der produktionsnahen Infrastruktur. Über das Industrial Edge Management werden die in der Cloud trainierten Modelle in containerisierter Form (Docker-Image) paketiert und auf die Edge-Geräte der Produktionsumgebung ausgerollt. Dort werden sie mit nahezu Echtzeitdaten aus den laufenden Prozessen gespeist und führen kontinuierlich Inferenzläufe zur Zustandsbewertung durch. Durch die lokale Bereitstellung auf dem Industrial Edge ist keine permanente Cloud-Verbindung erforderlich, wodurch sowohl die Latenzzeit minimiert als auch die Datensouveränität innerhalb des industriellen Netzwerks gewährleistet wird.




Abbildung 29: Schematische Darstellung Modellierung und Bereitstellung

Die **Abbildung 30** zeigt das im Überwachungssystem umgesetzte Dashboard, das die kontinuierliche Ergebnisse der Modelle mit Echtzeitdaten visualisiert. Für jeden Verdrängerzylinder wird der aktuelle Modellzustand dargestellt, wobei *i. O.* (intakt) mit dem Wert 0 und *n. i. O.* (fehlerhaft) mit dem Wert 1 codiert ist. Im rechten oberen Bereich sind der Verbindungsstatus zum X-Tools Storage und zum MQTT-Broker in Ampellogik integriert, wobei eine grüne Markierung eine aktive und stabile Verbindung signalisiert. Das Dashboard dient somit als Schnittstelle zwischen der modellbasierten Zustandsbewertung und der operativen Anlagenüberwachung, wodurch der Übergang von der analytischen Modellphase zur produktionsintegrierten Anwendung realisiert wird.

Darüber hinaus ist das Dashboard so konfiguriert, dass bei Auftreten eines *n. i. O.*-Zustandes eine automatische E-Mail-Benachrichtigung ausgelöst wird. Hierdurch wird der Forschende sowie das Instandhaltungspersonal unmittelbar über potenzielle Abweichungen oder Störungen im Anlagenverhalten informiert, ohne die laufende Überwachung aktiv verfolgen zu müssen. Diese Funktionalität erweitert die modellbasierte Zustandsbewertung um eine proaktive Benachrichtigungskomponente und trägt damit zur Erhöhung der Reaktionsgeschwindigkeit sowie zur frühzeitigen Einleitung von Korrekturmaßnahmen im Produktionsprozess bei.




Abbildung 30: Dashboard zur modellbasierten Zustandsüberwachung

Die produktive Implementierung der intelligenten Data Pipeline ermöglichte im betrachteten Anwendungsfall eine frühzeitige Erkennung eines sich anbahnenden Schadens an der Pressenlinie. Wie in **Abbildung 31** dargestellt, detektierte das trainierte Modell am **24. Oktober 2023 um 23:14 Uhr** eine signifikante Abweichung am Verdränger 8 und löste automatisiert eine Anomalie-Meldung aus. Die Meldung wurde systemseitig über das Überwachungssystem generiert und zusätzlich per E-Mail-Benachrichtigung an die zuständigen Fachbereiche übermittelt. Etwa vier Stunden nach dieser Meldung, gegen **03:30 Uhr** des Folgetages, traten im Werkstatt- und Anlagenbuch mehrere Störungsmeldungen auf, die eine Funktionsstörung des betreffenden Verdrängers bestätigten. Damit konnte retrospektiv nachgewiesen werden, dass der bevorstehende Ausfall durch das Modell korrekt und zeitlich signifikant vor dessen tatsächlichem Eintritt erkannt

wurde. Obwohl die technische Integration der Modelle in den produktiven Betrieb erfolgreich umgesetzt war, zeigte sich an dieser Stelle eine organisatorische Lücke. Zum Zeitpunkt des Ereignisses war die Instandhaltungsorganisation noch nicht vollständig auf das automatisierte Meldesystem ausgerichtet. Die generierte Warnmeldung wurde daher nicht unmittelbar in den operativen Entscheidungsprozess einbezogen, sodass der Stillstand infolge des Defekts an Verdränger 8 dennoch eintrat. Der Vorfall verdeutlicht, dass die reine technische Implementierung eines KI-basierten Überwachungssystems nicht ausreicht, um den vollen Nutzen datengetriebener Instandhaltung zu realisieren. Erst durch die organisatorische Integration kann das Potenzial der intelligenten Data Pipeline vollständig ausgeschöpft werden.




Abbildung 31: Chronologie Schaden Pressenlinie

Die Ziehkissen-Fallstudie verfolgte über die Beantwortung der Forschungsfragen hinaus das Ziel, die in **Kapitel 6.3.2** beschriebene intelligente Data Pipeline unter realen Produktionsbedingungen zu erproben und deren Datendurchgängigkeit nachzuweisen. Hierzu wurde der vollständige Verarbeitungspfad end-to-end umgesetzt: kontinuierliche Datenerfassung, qualitätssichernde Aufbereitung und manuelles Labeling, merkmalsbasierte Feature-Extraktion, modellbasiertes Training (Random-Forest-Klassifikator) sowie containerisierte Bereitstellung (Docker) auf dem Industrial Edge mit nachgelagerter Visualisierung und Alarmierung. Die inferenzielle Bewertung lief produktionsnah auf dem Industrial Edge, wobei Zustände im Dashboard binär (i. O.=0 / n. i. O.=1) dargestellt und im Anomaliefall per E-Mail gemeldet wurden. Im Betrieb wurde ein drohender Ausfall an Verdränger 8 etwa vier Stunden vor Eintritt detektiert. Der trotzdem aufgetretene Stillstand ist auf organisatorische Faktoren (unzureichende Einbindung der Instandhaltungsprozesse) und nicht auf technische Defizite der Pipeline zurückzuführen. Somit ist die Datendurchgängigkeit der technisch implementierten intelligenten Data Pipeline empirisch belegt. Ein Konzept zur Modellalterung und zum periodischen Nachtrainieren wurde zwar entwickelt, stand jedoch nicht im Zentrum des Nachweises. Entscheidend ist der gezeigte robuste und reproduzierbare End-to-End-Datenfluss mit wirksamer Modellintegration und operabler Ergebnisbereitstellung im industriellen Umfeld.

6.4.2 Zahnstangenantrieb

Im Gegensatz zur Ziehkissen-Fallstudie unterscheidet sich die Untersuchung des Zahnstangenantriebs sowohl in ihrer methodischen Herangehensweise als auch in ihrer Zielsetzung. Neben der Beantwortung der in **Kapitel 4.2** formulierten Forschungsfragen steht hier insbesondere die Entwicklung und Validierung realitätsnaher Modelle auf Basis eines Transfer-Simulators im Vordergrund. Dieser Ansatz ermöglicht es, simulierte Prozesszustände mit realen Produktionsdaten zu vergleichen und dadurch sowohl die Modellgüte als auch die technische Umsetzbarkeit im produktionsnahen Umfeld zu bewerten. Die Fallstudie verfolgt somit zwei zentrale Zielrichtungen. Zum einen wird die datenbasierte Modellierung und Validierung eines presswerkspezifischen Objekts ermöglicht, zum anderen werden exemplarische Ansätze zur Übertragbarkeit der entwickelten Methodik auf andere Produktionsdomänen abgeleitet. Diese Übertragbarkeit wird im Rahmen von **Kapitel 7.2** vertieft betrachtet. Der Einsatz des Transfer-Simulators bietet dabei mehrere Vorteile. Einerseits ist keine direkte Anbindung an das produktive Netzwerk erforderlich, wodurch experimentelle Untersuchungen unter realitätsnahen Bedingungen ohne Eingriff in den laufenden Betrieb ermöglicht werden. Andererseits können gezielt Fehlerszenarien reproduzierbar erzeugt werden, indem Zahnstangen mit unterschiedlichen Abnutzungsgraden eingesetzt werden. Darüber hinaus dient der im betrachteten Presswerk vorhandene Simulator als Schulungsanlage, was die Einbindung des Betriebspersonals in den Entwicklungsprozess erleichtert und die Akzeptanz datenbasierter Methoden in der Praxis fördert. Die Untersuchung des Zahnstangenantriebs wurde im Rahmen einer Forschungskollaboration mit der inpro mbH durchgeführt. Die Unterstützung durch den Industriepartner bezog sich dabei in dem Kontext des Zahnstangenantriebs nicht auf die Implementierung der Datenpipeline, sondern auf ausgewählte experimentelle und analytische Aspekte der Modellbildung. Die Zusammenarbeit umfasste insbesondere das Feature Engineering, die Durchführung gezielter Experimente mit defekten Bauteilen an einem Transfersimulator sowie die Annotation und Aufbereitung der gewonnenen Datensätze. Aus der gemeinsamen Entwicklung ging ein Patent hervor, das die Innovationshöhe und den industriellen Anwendungsbezug des Ansatzes unterstreicht (vgl. **Anhang D**).

(1)**Anwendungsverständnis.** Der Zahnstangenantrieb des Transfer-Simulators bildet das zentrale Antriebssystem für die horizontale Bewegung der Transferbalken in einer mehrstufigen Pressenlinie. In einem realen Produktionsumfeld dient der Transfer dazu, Werkstücke nach jedem Umformschritt von einer Station zur nächsten zu bewegen. Er übernimmt somit die werkstückseitige Handhabung zwischen den einzelnen Umformoperationen und gewährleistet einen kontinuierlichen Materialfluss innerhalb der Pressenlinie. Das Transfersystem ist wie in **Abbildung 32** zu sehen kinematisch so aufgebaut, dass es die dreidimensionale Bewegung der Greiferbalken über ein Zusammenspiel mehrerer Achsen ermöglicht. Die Vertikalbewegung wird durch die sogenannte Z-Achse realisiert, welche das Anheben und Absenken der Greiferbalken steuert, um Werkstücke aufzunehmen oder abzulegen. Ergänzend dazu ermöglicht die Y-Achse die Querbewegung der Balken und sorgt so für die Anpassung an unterschiedliche Werkzeugabstände und Bauteilgeometrien. Die X2-Achse übernimmt die Feinpositionierung des Kopfschlittens und gewährleistet

eine präzise Synchronisierung der Bewegungen während des Transfervorgangs. Den Hauptanteil der translatorischen Bewegung entlang der Pressenlinie übernimmt schließlich die X1-Achse, die als Hauptachse den gesamten Transfer horizontal verfährt und damit die zentrale Bewegungsachse des Systems bildet.




Abbildung 32: Schematischer Aufbau Transfersystem

Im Rahmen der vorliegenden Fallstudie steht ausschließlich die X1-Achse im Fokus der Betrachtung. Sie stellt die primäre Bewegungseinheit des Transfers dar und ist als Zahnstangenantrieb ausgeführt. Über diesen Antrieb erfolgt die translatorische Bewegung des Horizontalträgers, auf dem die weiteren Achsen gelagert sind. Der Servomotor der X1-Achse treibt über ein Ritzel die fest mit dem Maschinenbett verbundene Zahnstange an. Durch die rotatorische Bewegung des Motors wird eine lineare Verschiebung des Transferträgers erzeugt, wie sie in der schematischen Abbildung **Abbildung 32** dargestellt ist.

Diese Achse ist mechanisch hoch belastet, da sie die Gesamtmasse der Transferkonstruktion einschließlich der Greiferbalken und Werkstücke bewegt. Gleichzeitig erfordert der Produktionsprozess eine dynamisch präzise und wiederholgenaue Steuerung, um die geforderten Taktzeiten einzuhalten. Abweichungen oder Verschleißerscheinungen an der Zahnstange oder am Ritzel wirken sich unmittelbar auf die Bewegungsqualität und damit auf die Prozessstabilität aus. Der Transfer-Simulator ermöglicht die experimentelle Untersuchung dieser Bewegung unter realitätsnahen Bedingungen, ohne in das produktive Pressennetzwerk eingreifen zu müssen. Er bildet die X1-Achse einschließlich Servoantrieb, Zahnstange, Ritzel und Führungssystem originalgetreu ab und erlaubt so eine detaillierte Analyse des Bewegungsverhaltens sowie der entstehenden Antriebskräfte. Durch die modulare Bauweise ist es möglich, verschiedene Zahnstangen mit definierten Abnutzungs- oder Defektszenarien zu montieren und deren Einfluss auf das Systemverhalten zu untersuchen.

Zur Simulation von Fehlerszenarien wurden neben intakten Zahnstangen gezielt beschädigte Varianten eingesetzt, wie sie in **Abbildung 33** zu sehen sind. Diese weisen unterschiedliche Abnutzungs- und Bruchzustände auf, die charakteristische Defektbilder nachbilden. Bei der Abnutzungsvariante (AV) wurden die Zahnflanken an mehreren aufeinanderfolgenden Zähnen um etwa 1 mm (Defektgrad 1, AV1) bzw. 2 mm (Defektgrad 2, AV2) abgeschliffen, um den Effekt fortschreitenden Verschleißes zu simulieren. Die Defekte wurden im Bereich zwischen 250 mm und 320 mm der X1-Achse eingebracht. In einer weiteren Konfiguration wurde ein Zahnbruch (ZB) nachgebildet, bei dem in der Zahnstange

entweder ein Teil des Zahnes (Defektgrad 1, ZB1) oder ein vollständiger Zahn (Defektgrad 2, ZB2) entfernt wurde. Diese Defekte befinden sich im Bereich zwischen 560 mm und 600 mm der X1-Achse. Die entsprechenden realen Defektstellen sind in der **Abbildung 33** dargestellt.




Abbildung 33: Eingebaute Zahnstangendefekte

Durch den gezielten Einbau dieser defekten Zahnstangen in den Transfer-Simulator konnte der Einfluss der unterschiedlichen Defektarten auf die Bewegung der X1-Achse experimentell untersucht werden. Gleichzeitig erlaubte der Aufbau, die Sensitivität datenbasierter Modelle gegenüber mechanischen Abweichungen zu validieren und die Erkennbarkeit charakteristischer Anomalien im Bewegungsprofil zu bewerten.

(2) Datenvorbereitung. Die im Rahmen der Analyse des Zahnstangenantriebs verwendeten Daten wurden nicht aus der produktiven Umformanlage, sondern direkt aus dem Steuerungssystem des Transfer-Simulators gewonnen. Der Simulator ist netzwerktechnisch identisch zur produktiven Infrastruktur aufgebaut und nutzt ebenfalls das X-Tools-Kommunikationssystem als Datenschnittstelle. Dadurch konnte die in der Produktionsumgebung implementierte intelligente Data Pipeline annähernd abgebildet und hinsichtlich ihrer Funktionalität überprüft werden. Die Datenerfassung erfolgte kontinuierlich im Rahmen der Versuchsreihen über die X-Tools-Schnittstelle, über welche die relevanten Sensorsignale des Zahnstangenantriebs in definierten Zeitintervallen aufgezeichnet wurden. Zu den erfassten Signalen zählen u.a. die Ist-Lage, Soll-Lage, der Motorstrom sowie die Drehzahl des X1-Antriebs (vgl. **Tabelle 11**). Diese Größen beschreiben das dynamische Verhalten des Antriebs und sind somit zentral für die Bewertung des mechanischen und elektrischen Zustands des Systems.

Die strukturierte Vorbereitung der Daten erfolgt gemäß dem ETL-Prozess. Die aufgezeichneten Messdaten wurden in Echtzeit an den lokalen Speicher des Systems übermittelt und dort auf einer HDD im CSV-Format gesichert. Durch diese Vorgehensweise war es möglich, die Datenerhebung unter realitätsnahen Bedingungen ohne Eingriff in das produktive Presswerknetzwerk durchzuführen. Anschließend wurden die Daten formatiert, zeitlich synchronisiert und nach Funktionsgruppen des Antriebssystems segmentiert. Durch die Zusammenführung der einzelnen Datensätze über den Zeitstempel konnte eine

Tabelle 11: Übersicht Sensorsignale Zahnstangen-Fallstudie

Sensorname	Beschreibung	Datentyp
Zeitstempel	Tag und Zeit Sensorwert	string
X1_Lageistwert [F0–F6]	Ist-Position Transfer [mm]	integer
X1_Lagesollwert[F0–F6]	Soll-Position Transfer [mm]	integer
X1_Drehzahlwert [F0–F6]	Drehzahl Antrieb [1/min]	integer
X1_Phasenstromwert [F0–F6]	Motorstrom [A]	integer
Pressenposition	Kurbelwellenposition [°]	integer
Werkzeugnummer	Nummer des eingesetzten Werkzeuges	integer

eindeutige Zuordnung der Signale zueinander hergestellt werden. Dadurch war es möglich, verschiedene physikalische Größen, wie beispielsweise den Motorstrom über die jeweilige Pressenposition zu legen. Diese zeitlich-räumliche Verknüpfung, die als Signalverlauf in **Abbildung 34** zu sehen ist, ermöglichte eine direkte Korrelation zwischen dem elektrischen Energiebedarf und der mechanischen Bewegung des Antriebs, wodurch eine präzise Analyse des Betriebszustands und möglicher Unregelmäßigkeiten erfolgen konnte.




Abbildung 34: Exemplarischer Signalverlauf Transfer

Die **Abbildung 34** zeigt den mittleren Stromverlauf des X1-Antriebs über die Pressenposition sowie die zugehörige Standardabweichung, die als graue Fläche um den Mittelwert dargestellt ist, wobei eine intakte Zahnstange (IZ) eingebaut war. Der Verlauf beschreibt das elektrische Verhalten des Zahnstangenantriebs während eines vollständigen Transferzyklus im Transfer-Simulator. In der dargestellten Kurve sind mehrere charakteristische Abschnitte erkennbar, die auf unterschiedliche Bewegungsphasen des Transfers zurückzuführen sind. Zu Beginn des Zyklus weist der Stromverlauf nur geringe Schwankungen auf, die der Beschleunigungsphase des Antriebs entsprechen. Anschließend folgen markante Stromspitzen, die auf Phasen mit erhöhtem Lastmoment hinweisen, wie etwa beim Einfahren in den Umkehrpunkt oder beim Anfahren der maximalen Verfahrgeschwindigkeit.

Diese Spitzen sind typisch für dynamische Systeme mit hohem Trägheitsmoment und verdeutlichen die Lastwechsel, die auf die Zahnstange wirken. Die Standardabweichung liefert ein Maß für die Signalstabilität und Wiederholgenauigkeit über mehrere Zyklen. Niedrige Standardabweichungen deuten auf einen stabilen und reproduzierbaren Antriebsverlauf hin, während erhöhte Werte auf Unregelmäßigkeiten oder inkonsistente Bewegungsprofile hindeuten können. In einzelnen Bereichen mit ausgeprägter Varianz ist somit eine erhöhte Empfindlichkeit gegenüber Verschleiß, Zahnungstoleranzen oder geringfügigen mechanischen Abweichungen zu vermuten. Insgesamt zeigt der Verlauf, dass der Stromverbrauch stark von der jeweiligen Position innerhalb des Presszyklus abhängt. Durch die Zuordnung des elektrischen Stromsignals zur Pressenposition wird eine orts aufgelöste Analyse des Antriebsverhaltens ermöglicht, wodurch sich Abweichungen infolge mechanischer Veränderungen präzise lokalisieren lassen.

Vor der eigentlichen Modellierung wurde untersucht, wie sich mechanischer Verschleiß in Form von Abnutzung und Zahnbruch, wie sie in **Abbildung 33** zu sehen sind, auf das elektrische Verhalten des Zahnstangenantriebs auswirkt. Ziel dieser Analyse ist es, charakteristische Signalveränderungen zu identifizieren, die Rückschlüsse auf den technischen Zustand des Antriebs zulassen. Somit liegen Versuchsreihen sowohl für intakte Zahnstangen als Referenz als auch Varianten mit gezielt eingebrachten Abnutzungs- und Bruchstellen. Die Abnutzung wurde dabei in zwei Stufen (AV1, AV2) simuliert, bei denen die Zahnflanken an mehreren aufeinanderfolgenden Zähnen um etwa 1 mm bzw. 2 mm abgeschliffen wurden. Die **Abbildung 35** zeigt exemplarisch die Auswirkungen von Zahnflankenabnutzung (Defektgrad 2, AV2) auf den Stromverlauf des X1-Antriebes über die Pressenposition.




Abbildung 35: Auswirkungen auf die Sensorsignale durch Verschleiß

In der linken Darstellung ist der gemessene Stromverlauf über mehrere Zyklen gezeigt, während die rechte Darstellung die erste Ableitung des Signals abbildet. Diese dient zur Hervorhebung lokaler Änderungen in der Signalsteigung, die durch mechanische Unregelmäßigkeiten der Zahnstange verursacht werden. Die im linken Plot markierten Bereiche kennzeichnen die Positionen, an denen sich die Defektstellen auf der Zahnstange befinden. An diesen Stellen ist ein charakteristischer Anstieg der Stromamplitude zu erkennen, der auf einen kurzzeitigen Lastanstieg im Antrieb hinweist. Ursache hierfür ist der Verlust einer gleichmäßigen Kraftübertragung infolge der abgeschliffenen Zahnflanken. Das resultierende Momentenungleichgewicht führt zu kurzzeitigen Stromspitzen, die als Anomalien im Signalverlauf detektierbar sind. In der rechten Darstellung wird die Ableitung des Stromsignals über die Pressenposition gezeigt. Durch die Differenzbildung (dy) und

die Betrachtung innerhalb schmaler Fenster (Fensterbreite) können Änderungen in der Signalsteigung quantitativ erfasst werden. Besonders in den Bereichen der defekten Stellen treten deutlich erhöhte dy -Werte auf, die symmetrisch um die x -Achse angeordnet sind. Diese Peaks kennzeichnen abrupte Übergänge im Kraftfluss und stellen ein charakteristisches Merkmal für Zahnflankenabnutzung dar. Die Analyse zeigt, dass die Kombination aus Stromverlauf und Ableitung eine zuverlässige Möglichkeit bietet, den Einfluss von Abnutzung auf das elektrische Verhalten des Zahnstangenantriebs sichtbar zu machen. Durch die segmentweise Auswertung der maximalen Steigungsänderungen lassen sich Defektbereiche präzise lokalisieren und in den weiteren Modellierungsschritt überführen.

Die **Abbildung 36** zeigt die Auswirkungen eines Zahnbruchs (Defektgrad 2, ZB2) auf das Signalverhalten des Zahnstangenantriebs. Dargestellt ist der Drehzahlverlauf des X1-Antriebes über die Pressenposition im Vergleich zwischen einem intakten Zustand (IZ) und dem Defektfall (ZB2). Ergänzend ist die Standardabweichung als graue Fläche eingezeichnet, um die Streuung der Signalwerte über mehrere Zyklen sichtbar zu machen. Im Vergleich der beiden Kurvenverläufe wird deutlich, dass der Zahnbruch zu einer lokalen Abweichung in der Drehzahl führt. Diese Abweichung tritt in einem eng begrenzten Positionsbereich auf, der der Lage der defekten Stelle auf der Zahnstange entspricht. Während der intakte Verlauf eine gleichmäßige Drehzahlreduktion zeigt, weist die Kurve des Defektfalles in diesem Abschnitt eine signifikante Absenkung auf. Ursache ist der kurzzeitige Verlust der Kraftübertragung, der durch das Fehlen eines Zahnes entsteht. Dieser Momenteneinbruch führt zu einer kurzzeitigen Entlastung des Antriebes, wodurch die Drehzahl in diesem Bereich geringer ausfällt. Zur quantitativen Bewertung wird die Fläche zwischen den Kurvenverläufen innerhalb einer definierten Fensterbreite berechnet. Dieses Integral stellt ein Maß für die Abweichung des Defektfalles vom Referenzsignal dar und charakterisiert damit den Einfluss des Zahnbruchs auf das dynamische Verhalten des Antriebs. In der Abbildung ist die entsprechende Fläche graphisch hervorgehoben. Die Standardabweichung bestätigt die systematische Natur der beobachteten Abweichung. In der Umgebung der Defektstelle ist eine deutliche Erhöhung der Streuung erkennbar, während in den übrigen Bereichen des Zyklus keine signifikanten Varianzen auftreten. Damit lässt sich ausschließen, dass die beobachtete Signalveränderung auf zufällige Schwankungen zurückzuführen ist. Die Analyse zeigt, dass durch lokale Drehzahlabweichungen Defekte charakterisiert werden können. Die Kombination aus Kurvenvergleich und Varianzbewertung ermöglicht es somit, Defektstellen eindeutig zu identifizieren und deren Einfluss auf das Bewegungsverhalten zu quantifizieren.

Zur systematischen Bewertung der zuvor beschriebenen Signalveränderungen infolge von Abnutzung und Zahnbruch wurde eine Merkmalsextraktion durchgeführt, die auf den Stromsignalen des X1-Antriebs basiert. Ziel war es, charakteristische Kenngrößen zu identifizieren, die eine eindeutige Trennung der Zustände ermöglichen und als Eingangsgrößen für die spätere Modellierung dienen.

Hierzu wurden aus den aufgezeichneten Stromsignalen zweierlei Merkmale gebildet. Zum einen das Integral des Stromverlaufs über definierte Fensterbereiche, das die energetische Abweichung zwischen dem fehlerfreien und dem defekten Zustand beschreibt, und zum anderen die Steigungsänderung $dy(I)$ des Stromsignals, welche die Dynamik der Stromän-




Abbildung 36: Auswirkungen auf die Sensorsignale durch Zahnbruch

derung im zeitlichen Verlauf charakterisiert. Das Integral liefert ein Maß für den zusätzlichen Energieeintrag infolge mechanischer Störungen, während $dy(I)$ lokale Unregelmäßigkeiten in der Signalform hervorhebt, wie sie beispielsweise durch Zahnflankenabnutzung oder ruckartige Bewegungen entstehen.

Die Kombination dieser beiden Merkmale erlaubt die zweidimensionale Abbildung des Antriebsverhaltens in einem Merkmalsraum (vgl. **Abbildung 37**). Jeder Punkt in der Darstellung repräsentiert dabei einen vollständigen Hub des Transfersystems. Gleiche Punktformen entsprechen identischen Transferstufen, während die Farbgebung den jeweiligen Verschleiß- oder Defektzustand kennzeichnet. Auf diese Weise konnte eine visuelle Clusterbildung der unterschiedlichen Betriebszustände erreicht werden.




Abbildung 37: Merkmalsextraktion Sensorsignale X1-Antrieb

In der resultierenden Merkmalsverteilung zeigen die intakten Zustände IZ kompakte

und eng beieinanderliegende Cluster mit geringen Integral- und dy-Werten, was auf einen stabilen und gleichmäßigen Betrieb hinweist. Die Abnutzungszustände AV1 und AV2 bilden Übergangsbereiche mit leicht erhöhten Integral- und Steigungswerten und markieren den beginnenden Verschleiß. Die Zahnbruchzustände ZB1 und ZB2 hingegen liegen deutlich außerhalb dieser Cluster und weisen signifikant höhere Merkmalsausprägungen auf, was den abrupten Eingriff der Fehlstelle in die Antriebsdynamik widerspiegelt. Diese klare Trennbarkeit der Zustände zeigt, dass die gewählten Merkmale sowohl für die Zustandsklassifikation als auch für die automatisierte Anomalieerkennung geeignet sind. Die Analyse bildet somit die Grundlage für den nachfolgenden Modellierungsschritt, in dem die gewonnenen Merkmale zur datenbasierten Bewertung und Erkennung von Verschleißzuständen genutzt werden.

(3) Modellierung und Ergebnisinterpretation. Für die datenbasierte Zustandsklassifikation des Zahnstangenantriebs wurde im ersten Schritt ein überwachtes Lernverfahren implementiert, das auf einem Multilayer Perceptron (MLP) basiert (vgl. **Kapitel 3.3.3**). Ziel dieser Modellierungsstrategie war es, auf Grundlage der zuvor extrahierten Merkmale eine automatisierte Erkennung und Zuordnung der verschiedenen Verschleiß- und Defektzustände zu ermöglichen. Die für das Training und die Validierung des Modells verwendeten Datensätze stammen gemäß der Systematik der Datenerhebung von Messreihen des Transfer-Simulators. Zur besseren Vergleichbarkeit wurden die Fahrprofile der X1-Achse um 200° in die Ruhelage verschoben, um Überlagerungen oder unvollständige Bewegungszyklen zu vermeiden. Anschließend wurden die Kurvenverläufe der einzelnen Hübe in definierte Segmente, wie sie in **Abbildung 38** unterteilt, um die Defektlokalisierung zu ermöglichen.




Abbildung 38: Segmentierung der Kurvenverläufe X1-Antrieb

Die Segmentierung erfolgte so, dass die Bereiche um die bekannten Defektstellen (AV1, AV2, ZB1, ZB2) besonders berücksichtigt wurden. Zur Erhöhung der Varianz wurde zusätzlich pro Hub ein zufälliger Abschnitt aus dem fehlerfreien Zustand (IZ) ergänzt, wodurch ein ausgewogenes Verhältnis zwischen intakten und defekten Signalabschnitten gewähr-

leistet werden konnte. Der Mittelpunkt jedes Defektbereichs wurde dabei als Referenzpunkt der jeweiligen Fehlstelle definiert. Insgesamt umfasste der Datensatz rund 12.000 Segmente aus den Transferstufen T1, T2, T3, T5 und T6 als Trainingsdaten sowie etwa 4 500 Segmente aus den Transferstufen T4 und T7 zur Validierung. Als Eingangsgrößen des MLP dienten die im Rahmen der Merkmalsextraktion gebildeten Kennwerte mit den Steigungsänderungen $dy(Strom)$ und $dy(Drehzahl)$, den Integralen $Integral(Strom)$ und $Integral(Drehzahl)$ sowie der Verfahrensgeschwindigkeit v als zusätzliche Inputgröße. Letztere wurde eingeführt, da durch das positionsabhängige Sampling die Zeitinformation verloren geht und die Geschwindigkeit eine entscheidende Kontextgröße für die korrekte Interpretation der Signaländerungen darstellt. Die Architektur des Modells bestand aus einem Input-Layer, mehreren Hidden-Layern und einem Output-Layer, der die Klassenzuordnung zur jeweiligen Defektklasse (AV1, AV2, ZB1, ZB2) vornimmt. Die verborgenen Schichten wurden so dimensioniert, dass eine ausreichende Komplexität zur Erkennung nichtlinearer Zusammenhänge gewährleistet ist, ohne das Modell zu überanpassen. Das Training des Modells erfolgte überwacht anhand der bekannten Defektklassen. Dabei wurde die Fehlerfunktion durch Rückwärtspropagation minimiert und die Gewichts Anpassung iterativ optimiert. Zur Vermeidung von Overfitting wurde ein Teil der Trainingsdaten (Transferstufen T4 und T7) als unabhängiger Testdatensatz reserviert.

Wie in **Abbildung 39** zu sehen, wurden zur Bewertung der Modellgüte mehrere Konfusionsmatrizen herangezogen, die unterschiedliche Aggregationsebenen abbilden. Während die **Abbildung 39** links die binäre Klassifikation in „intakt“ (0) und „Anomalie“ (1) einteilt, stellt die rechte Seite eine Mehrklassenklassifikation unter Einbezug der Abnutzung sowie der Bruchs.




Abbildung 39: Konfusionsmatrizen MLP

Für die Anomaliedetektion ergeben sich folgende Werte für die Modellgüte:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{1565 + 2792}{4570} = \frac{4357}{4570} = \mathbf{95,34\%}$$

$$Precision = \frac{TP}{TP + FP} = \frac{2792}{2792 + 31} = \frac{2792}{2823} = \mathbf{98,90\%}$$

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{2792}{2792 + 182} = \frac{2792}{2974} = \mathbf{93,88\%}$$

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \cdot \frac{0,9890 \cdot 0,9388}{0,9890 + 0,9388} = \mathbf{96,3\%}$$

Demnach erkennt das MLP intakte und anomale Zustände sehr zuverlässig. Mit einer Gesamterkennungsrate von 95,3 % und einem F1-Score von 96,3 % erreicht das Modell eine hohe Trennschärfe. Die Präzision beträgt 98,9 %, was auf eine geringe Fehlklassifikation intakter Zustände hinweist. Die etwas geringere Recall-Rate mit 9,9 % zeigt, dass vereinzelte Anomalien fälschlich als i.O. klassifiziert werden, was typisch für konservative Klassifikatoren mit niedriger False-Positive-Rate ist.

Für die erweiterte Kofusionsmatrix in Bezug auf die Defektklassifikation ergeben sich folgende Kennzahlen für die Modellgüte:

$$\text{Accuracy} = \frac{TP_{\text{I.O.}} + TP_{\text{AV}} + TP_{\text{ZB}}}{N} = \frac{1565 + 1868 + 497}{4570} = \frac{3930}{4570} = \mathbf{85,99\%}$$

Für die Klasse Zahnstangenabnutzung (AV) gilt:

$$\text{Precision}_{\text{AV}} = \frac{TP}{TP + FP} = \frac{1868}{1868 + 4 + 326} = \frac{1868}{2198} = \mathbf{85,0\%}$$

$$\text{Recall}_{\text{AV}} = \frac{TP}{TP + FN} = \frac{1868}{1868 + 19 + 101} = \frac{1868}{1988} = \mathbf{93,96\%}$$

$$F1_{\text{AV}} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \cdot \frac{0,85 \cdot 0,9396}{0,85 + 0,9396} = \mathbf{89,2\%}$$

Für die Klasse Zahnbruch (ZB) ergibt sich entsprechend:

$$\text{Precision}_{\text{ZB}} = \frac{TP}{TP + FP} = \frac{497}{497 + 27 + 101} = \frac{497}{625} = \mathbf{79,5\%}$$

$$\text{Recall}_{\text{ZB}} = \frac{TP}{TP + FN} = \frac{497}{497 + 163 + 326} = \frac{497}{986} = \mathbf{50,4\%}$$

$$F1_{\text{ZB}} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \cdot \frac{0,795 \cdot 0,504}{0,795 + 0,504} = \mathbf{61,8\%}$$

Das Modell erreicht damit eine Gesamtgenauigkeit von 85,99 %. Die Klasse Zahnstangenabnutzung wird mit hoher Präzision und Zuverlässigkeit erkannt ($F1 = 89,2\%$), während die Erkennungsrate bei Zahnbrüchen aufgrund der lokal begrenzten Signalverläufe geringer ausfällt ($F1 = 61,8\%$). Damit bestätigt sich, dass das Modell Verschleißzustände robust identifiziert, bei diskontinuierlichen Störereignissen jedoch noch Optimierungspotenzial besteht.

Die Resultate verdeutlichen, dass die auf Strom- und Drehzahlsignalen basierenden Merkmale eine hohe Sensitivität gegenüber strukturellen Veränderungen des Antriebs aufweisen. Das MLP-Modell erkennt insbesondere Abnutzungsvorgänge mit hoher Präzision,

während Zahnbrüche aufgrund ihres lokal begrenzten Auftretens und der variablen Signalintensität eine größere Streuung verursachen. Trotz dieser Einschränkungen stellt der Ansatz einen erfolgreichen Nachweis dar, dass die implementierte intelligente Data Pipeline in der Lage ist, auf Basis von Produktionssignalen datengetriebene Klassifikationsmodelle zu trainieren und Defektzustände reproduzierbar zu erkennen. Damit ist gezeigt, dass die entwickelte Methodik eine solide Grundlage für weiterführende Modellverfeinerungen und die Integration in Echtzeitanwendungen auf dem Industrial Edge bietet.

Die zeitlichen Signalverläufe der Prozessgrößen ähneln sich in ihrer Struktur stark mit denjenigen, die durch reguläre Prozessschwankungen hervorgerufen werden. Aus diesem Grund wurde ein weiteres Verfahren entwickelt, das das Regelverhalten des Antriebs selbst in den Mittelpunkt der Betrachtung stellt. Dadurch können Abweichungen in der zeitlichen Abfolge der Regelgrößen als Indikatoren für mechanische Veränderungen genutzt werden.

Die Regelung erfolgt nach dem Prinzip einer translatorischen Positionsregelung (vgl. **Abbildung 40**), bei der die Soll-Position der Zahnstange als Führungsgröße vorgegeben und über den Motorstrom und die resultierende Drehzahl auf die Ist-Position geregelt wird. Die Führungsgröße des Regelkreises ist somit die vorgegebene Lage-Soll-Position, die Regelgröße ist die gemessene Lage-Ist-Position, und die Stellgröße ist der vom Regler ausgegebene Motorstrom. Die Drehzahl fungiert als Zwischengröße innerhalb der Regelstrecke und beschreibt die dynamische Reaktion des Motors auf den Stellstrom. Sämtliche Wirkzusammenhänge innerhalb des Regelkreises sind mit zeitlichen Verzögerungen behaftet, die auf das Massenträgheitsmoment der mechanischen Komponenten zurückzuführen sind. Wird ein Stromimpuls an den Motor angelegt, führt dies erst nach einer endlichen Zeitspanne zu einer Änderung der Drehzahl, welche sich wiederum verzögert auf die Positionsänderung auswirkt. Diese Zeitdifferenz Δt stellt eine charakteristische Kenngröße des dynamischen Systemverhaltens dar und kann zur Bewertung von Abweichungen im Regelverhalten herangezogen werden. Eine Änderung der Drehzahl ohne vorhergehende Änderung des Motorstroms ist ein Hinweis auf eine mechanische Beeinflussung innerhalb des Antriebssystems. Diese kann beispielsweise durch erhöhte Reibung, Losbrechmomente oder fortgeschrittenen Zahnstangenverschleiß hervorgerufen werden. Das Regelverhalten dient somit als physikalisch begründete Basis für die Diagnose des Systemzustandes.




Abbildung 40: Regelverhalten X1-Antrieb

Zur datengetriebenen Beschreibung der Reglerdynamik wird ein Verfahren entwickelt, das die kausale Abfolge der physikalischen Größen durch rekurrente neuronale Netze (LSTM) und konvolutionale Strukturen (1D-CNN) abbildet (vgl. **Kapitel 3.3.3**). Die

Eingangsgrößen bilden die Messsignale des Motorstroms, der Drehzahl, der Lage-Ist sowie der Lage-Soll-Werte. Dabei ist die Modellierung LSTM auf Basis Reglerverhalten in **Abbildung 41** dargestellt.




Abbildung 41: Modellierung LSTM auf Basis Reglerverhalten

Das **Long Short-Term Memory (LSTM-Netzwerk)** wird zur Vorhersage der Drehzahl $\omega(t_{+1})$ eingesetzt. Grundlage bildet die zeitliche Reaktionskette des Reglers, die sich in vereinfachter Form wie folgt darstellen lässt:

$$\Delta x_{\text{Soll}} \rightarrow \Delta I \rightarrow \Delta \omega \rightarrow \Delta x_{\text{Ist}}$$

Das neuronale Netz wurde in der Softwareumgebung *TensorFlow* implementiert. Die Architektur umfasst eine Long Short-Term Memory (LSTM)-Schicht mit 150 Neuronen, die auf die Erfassung und Modellierung zeitlicher Abhängigkeiten innerhalb der Messdaten ausgelegt ist. Durch die interne Speicherstruktur der LSTM-Zellen können langfristige Abfolgen und dynamische Zusammenhänge im Regelverhalten abgebildet werden. Darauf folgt eine Regularisierungsschicht (*Dropout-Layer*), welche Überanpassungen während des Trainingsprozesses reduziert und so die Verallgemeinerungsfähigkeit des Modells erhöht. Die abschließende Ausgabeschicht (*Dense-Layer*) besteht aus 151 Neuronen mit ReLU-Aktivierungsfunktion und berechnet den vorhergesagten Verlauf der Motordrehzahl. Insgesamt umfasst das Modell rund 92 000 trainierbare Parameter, die während des Trainings iterativ angepasst werden, um die Abweichung zwischen vorhergesagtem und tatsächlichem Signalverlauf zu minimieren. Durch diese Netzwerkstruktur wird die zeitlich abhängige Wechselwirkung zwischen Motorstrom, Drehzahl und Position mit hoher Genauigkeit abgebildet, wodurch das charakteristische dynamische Verhalten des Reglers datenbasiert reproduziert werden kann. Ein Vergleich der vorhergesagten Drehzahlverläufe mit den gemessenen Signalen zeigt eine sehr gute Übereinstimmung für fehlerfreie Bewegungszyklen. Bei einsetzender oder fortschreitender Zahnstangenabnutzung hingegen treten charakteristische Abweichungen auf. Diese äußern sich in Phasenversätzen, Über- bzw. Unterschwingungen und gegengesätzlichen Steigungen zwischen vorhergesagtem und tatsächlichem Drehzahlverlauf. Das LSTM reagiert dabei auf einen mechanisch verursachten

Drehzahleinbruch mit einer verzögerten Anpassung, da die zugrunde liegende Stromänderung erst nachträglich eintritt. Die Modellantwort spiegelt somit den Regelversuch des Systems wider, den Drehzahleinbruch zu kompensieren. Je nach Ausprägung des mechanischen Defekts (leichte oder starke Abnutzung, teilweiser oder vollständiger Zahnbruch) variiert die Amplitude der Abweichung. Die zeitliche Struktur bleibt jedoch konsistent: Auf eine unerwartete Drehzahländerung folgt eine zeitverzögerte Kompensationsreaktion des Reglers. Dieses Verhalten bildet die Grundlage für die Erkennung von Regelabweichungen durch datengetriebene Verfahren.

Da sich die beschriebenen Effekte in ihrer Amplitude und Richtung stark unterscheiden und sich zudem mit externen Störeinflüssen überlagern können, wird zur robusten Erkennung von Abweichungsmustern ein One-Dimensional Convolutional Neural Network (1D-CNN) eingesetzt. Dieses Netz verarbeitet die zeitlichen Differenzen zwischen den durch das LSTM-Modell prognostizierten und den tatsächlich gemessenen Drehzahlverläufen und identifiziert charakteristische Signalstrukturen, die auf Regelabweichungen hinweisen. Das CNN operiert entlang der Zeitachse und ist darauf ausgelegt, lokale Muster und Frequenzanteile zu extrahieren, die Rückschlüsse auf den Systemzustand zulassen. Das Schaubild zur semantischen Abfolge ist in **Abbildung 42** dargestellt. Das Verfahren kombiniert beide Modellansätze in einer sequentiellen Datenpipeline, in der zunächst ein LSTM-Modell auf Grundlage der Eingangsgrößen den erwarteten Verlauf der Drehzahl prognostiziert. Die daraus resultierende Prognose wird anschließend mit den gemessenen Ist-Werten verglichen und als Eingabe für ein 1D-CNN verwendet, das die Abweichung zwischen Prognose und Messung analysiert und auf dieser Basis den aktuellen Zustand der Zahnstange klassifiziert. Durch die Kombination beider Netztypen entsteht ein hybrides Modell, das sowohl zeitliche Abhängigkeiten als auch lokale Merkmalsänderungen innerhalb der Signale erfassen kann. Auf diese Weise wird eine robuste datengetriebene Erkennung von mechanischen Verschleißzuständen auf Basis des dynamischen Regelverhaltens ermöglicht.




Abbildung 42: Schaubild Modellierungsschritte LSTM und 1D-CNN

Zur quantitativen Bewertung der Klassifikationsleistung des 1D-CNN wurde eine Kon-

fusionsmatrix erstellt, die das Ergebnis der Modellvorhersagen auf den Simulatordaten zusammenfasst (vgl. **Abbildung 43**). Die Matrix zeigt die Anzahl der korrekt und fehlerhaft klassifizierten Samples für die Klassen *i. O.* (0) und *n.i. O.* (1).

Tatsächlicher Wert []	0	24718	3453
	1	205	6698
		0	1
		Errechneter Wert []	

Abbildung 43: Konfusionsmatrix 1D-CNN

Die Ergebnisse zeigen eine hohe Übereinstimmung zwischen den vorhergesagten und den tatsächlichen Zuständen. Von den als *i. O.* simulierten Zuständen wurden 24.718 Fälle korrekt erkannt, was einer Genauigkeit von 99 % in dieser Klasse entspricht. Lediglich 205 Samples wurden fälschlicherweise als Anomalie klassifiziert. Für die als *n.i. O.* simulierten Fälle erkannte das Netzwerk 6.698 korrekt, was einer Klassifikationsgüte von 66 % in dieser Klasse entspricht. 3.453 fehlerhafte Einordnungen in die Klasse *i. O.* deuten darauf hin, dass das Netz bei schwach ausgeprägten Anomalien eine gewisse Unsicherheit zeigt. Insgesamt zeigt das Ergebnis, dass das entwickelte 1D-CNN eine hohe Sensitivität für reguläres Reglerverhalten besitzt und in der Lage ist, mechanische Abweichungen zuverlässig zu detektieren. Die verbleibenden Fehlklassifikationen lassen sich im Wesentlichen auf Überlagerungseffekte durch Prozessrauschen und den begrenzten Abbildungsbereich der Simulationsdaten zurückführen. Für eine weiterführende Optimierung wäre daher die Integration zusätzlicher Produktionsdatensätze mit verschiedenen Defektstufen zielführend, um die Robustheit des Netzes gegenüber realen Prozessschwankungen zu erhöhen.

(4) Bereitstellung. Der im Rahmen dieser Fallstudie entwickelte Ansatz zur modellbasierten Zustandserkennung der Zahnstange, bestehend aus der Kombination eines LSTM- und eines 1D-CNN-Modells, wurde zunächst in einer Simulationsumgebung konzipiert und trainiert. Auf diese Weise konnten die modellinternen Lernprozesse sowie die Interaktion zwischen den beiden neuronalen Netzen unabhängig von produktionsspezifischen Störgrößen untersucht werden. Analog zu den in der vorangegangenen Fallstudie beschriebenen Vorgehensweisen wurden die trainierten Modelle anschließend in das Industrial Edge Management überführt und dort als eigenständige Applikation installiert (vgl. **Anhang E Abbildung 61**). Die Implementierung erfolgte in der bestehenden Infrastruktur der intelligenten Data Pipeline, sodass die gesamte Datenkommunikation technisch abbildbar war. Im Gegensatz zu den zuvor produktiv eingesetzten Modellen

für das Ziehkissen wurde das Zahnstangenmodell jedoch nicht in den laufenden Produktionsbetrieb überführt. Ziel war zunächst, die Validierung und den stabilen Betrieb der Ziehkissen-Applikation abzuschließen, bevor mehrere datengetriebene Modelle parallel auf dem Industrial Edge betrieben werden. Dadurch konnten keine Erfahrungen hinsichtlich der gleichzeitigen Ausführung mehrerer Applikationen auf derselben Edge-Instanz gesammelt werden. Obwohl das entwickelte Modell technisch vollständig integrierbar und als lauffähige Applikation auf dem Edge-System bereitgestellt wurde, blieb ein direkter Mehrwert im produktiven Umfeld aus. Insbesondere fehlte der Bezug zu realen Produktionsdaten, die für eine kontinuierliche Modellvalidierung und Bewertung der Prognosegüte erforderlich wären. Dennoch zeigt die erfolgreiche Installation, dass die konzipierte Dateninfrastruktur eine hohe Flexibilität hinsichtlich der Einbindung externer Modelle aufweist. Somit konnte nachgewiesen werden, dass auch außerhalb der produktiven Umgebung entwickelte Algorithmen ohne strukturelle Anpassungen in das Ökosystem des Industrial Edge integriert werden können. Dieser Aspekt unterstreicht die Offenheit und Erweiterbarkeit der intelligenten Data Pipeline und belegt, dass sie nicht nur für die direkte Anbindung von produktionsintern generierten Modellen geeignet ist, sondern auch als Plattform zur Integration externer datengetriebener Anwendungen fungieren kann.

Zusammengefasst adressierte die Fallstudie primär die modellgetriebene Entwicklung und Validierung auf einem Transfer-Simulator. Neben dem ersten Ansatz der MLP-Anwendung, wurden auf Basis des vermuteten PID-Regelverhaltens ein LSTM zur Prognose des Drehzahlverlaufs und ein 1D-CNN zur Mustererkennung kombiniert. Der Simulator ermöglichte die reproduzierbare Erzeugung von Abnutzungs- und Bruchsszenarien und damit eine saubere Trennung zwischen Regelabweichungen und Störeinflüssen. Die Modelle wurden als Applikation im Industrial Edge Management installiert, jedoch nicht produktiv geschaltet. Folglich blieben eine Validierung an Realdaten und Erfahrungen zum Parallelbetrieb mehrerer Modelle daher aus. Trotzdem belegt die Fallstudie die Anschlussfähigkeit der intelligenten Data Pipeline in Anbetracht dessen, dass extern entwickelte Algorithmen sich mit geringem Integrationsaufwand in das Edge-Ökosystem überführen lassen und bilden damit die Grundlage für die in **Kapitel 7.2** diskutierte Übertragbarkeit auf weitere Produktionsdomänen.

6.4.3 Druckluftgreifer

Die nachfolgende Fallstudie adressiert den Druckluftgreifer als integralen Bestandteil des automatisierten Transfersystems innerhalb der betrachteten Pressenlinie. Im Gegensatz zu den zuvor untersuchten Anwendungsfällen steht hier nicht primär die Zustandsüberwachung einzelner mechanischer Komponenten im Fokus, sondern die datenanalytische Erschließung eines energieintensiven, zyklisch betriebenen pneumatischen Subsystems. Ziel der Analyse ist es, auf Basis hochaufgelöster Druck- und Volumenstromdaten zu untersuchen, inwieweit sich der physikalische Bewegungsablauf des Transfers sowie potenzielle Effizienzverluste oder Anomalien im Druckluftsystem datengetrieben abbilden lassen. Der Druckluftgreifer eignet sich dabei besonders als Analyseobjekt, da sein Betriebsverhalten eng mit der mechanischen Kurbelwellenbewegung der Pressenlinie gekoppelt ist und

sich diese Kopplung unmittelbar in charakteristischen Signalverläufen widerspiegeln sollte. Aufbauend auf diesem Zusammenhang wird im Folgenden zunächst das technische Wirkprinzip und der prozessuale Kontext des Druckluftgreifers beschrieben, bevor die darauf aufsetzende datenanalytische Untersuchung durchgeführt wird.

Die Entwicklung und Analyse des Anwendungsfalls erfolgte im Rahmen eines arbeitsteiligen Vorgehens, bei dem auf Grundlage der vom Verfasser bereitgestellten Datengrundlage einzelne operative Schritte, insbesondere die vergleichende Erprobung ausgewählter Analyseverfahren, durch studentische Mitarbeit unterstützt wurden [vgl. Jericho 2022]. Die konzeptionelle Ausgestaltung, die methodische Steuerung sowie die wissenschaftliche Einordnung der Ergebnisse lagen vollständig bei dem Forschenden. Teile der zugrunde liegenden Analyse wurden zudem gemeinsam mit *Wartenberg* wissenschaftlich weiterentwickelt und veröffentlicht und werden in der vorliegenden Arbeit in einen erweiterten industriellen und methodischen Gesamtkontext eingebettet (vgl. **Anhang D**; [vgl. Evirgen und Wartenberg 2024]).

(1) Anwendungsverständnis. Der Druckluftgreifer stellt innerhalb der Umformanlage eine zentrale Komponente des automatisierten Materialhandlings dar. Seine Hauptaufgabe besteht darin, Blechplatinen zwischen den einzelnen Pressenstufen einer Pressenlinie präzise aufzunehmen, zu transportieren und positionsgenau abzulegen. Der Transportvorgang erfolgt über sogenannte Transfer-Systeme, an deren Querträgern werkzeugspezifische Toolings mit pneumatischen Sauggreifern angebracht sind. Diese Toolings sind über flexible Leitungen an das zentrale Druckluftnetz der Pressenlinie angeschlossen und werden über Kompaktejektoren mit Vakuum versorgt.

Die Druckluftherzeugung und Vakuumgenerierung basiert auf dem Venturi-Prinzip und ist in **Abbildung 44** schematisch dargestellt. Dabei wird Druckluft mit einem vorgegebenen Betriebsdruck aus dem Kompressorsystem den Vakuumejektoren zugeführt. Dabei kann über einen Durchflusssensor die Durchflussmenge gemessen werden. Diese Ejektoren verfügen über eine speziell geformte Düse, durch die die Druckluft beschleunigt und in eine Engstelle geleitet wird. Beim Austritt aus dieser Engstelle expandiert die Strömung abrupt, wodurch ein Unterdruck im angeschlossenen Vakuumkanal entsteht. Dieser Unterdruck wird genutzt, um über die angeschlossenen Sauggreifer ein Vakuumnetz aufzubauen, das die Platine sicher fixiert und während des gesamten Transferzyklus hält.




Abbildung 44: Prinzip der Druckluftherzeugung

Kompaktejektoren vereinen in einer kompakten Bauform die Funktionen Saugen, Halten und Abblasen. Während der Haltephase wird der erzeugte Unterdruck durch Rückschlagventile im Ejektor aufrechterhalten, sodass kein kontinuierlicher Druckluftstrom er-

forderlich ist. Nach Abschluss des Transfervorgangs erfolgt die Ablage der Platine über eine integrierte Abblasfunktion. Hierbei wird für eine definierte, einstellbare Zeitspanne das zuvor evakuierte Vakuumnetz gezielt mit dem Druckluftnetz verbunden, wodurch ein schneller Druckanstieg erfolgt. Dieser sorgt dafür, dass die Platine aktiv von den Sauggreifern gelöst und sicher auf der nachfolgenden Pressenstufe abgelegt wird. Der Abblasvorgang ist so ausgelegt, dass die Druckänderung in sehr kurzer Zeit erfolgt, um einen effizienten Taktbetrieb zu ermöglichen. Über eine Drosselschraube am Kompaktejektor kann der Volumenstrom der Abblasluft feinjustiert werden, wodurch sich der Druckanstieg an unterschiedliche Werkstückgewichte und Oberflächen anpassen lässt. Damit vereint der Kompaktejektor sowohl die Funktionen des Vakuumerzeugers als auch des pneumatischen Schalters in einem einzigen Bauteil. Dieser Aufbau verdeutlicht, dass der Druckluftverbrauch direkt vom Bewegungszyklus des Transfers abhängt und jede Aktivierung der Ejektoren mit einer entsprechenden Druckluftspitze einhergeht. In der Praxis entstehen die größten Druckluftverluste durch Leckagen in den Leitungen, verschlissene Sauggreifer oder suboptimale Ejektoreinstellungen, wodurch übermäßige Druckluftvolumina verbraucht werden. Daher ist die kontinuierliche Messung des Druckluftvolumenstroms ein zentraler Bestandteil der datenanalytischen Betrachtung, um Abweichungen zwischen Soll- und Ist-Verbrauch frühzeitig zu erkennen.

Die **Abbildung 45** veranschaulicht den grundlegenden Ablauf eines Arbeitsschrittes sowie die Bewegungskurven des Transfers zwischen zwei Pressenstufen. Beim Einlegen der Platine in die erste Stufe und bei der Entnahme des Fertigteils aus der letzten Stufe ist dieser Ablauf prinzipiell identisch, weshalb der dargestellte Fall exemplarisch anhand zweier aufeinanderfolgender Stufen beschrieben wird. In Abhängigkeit von der Kurbelwellenposition der Presslinie vollzieht der Transfer eine zyklische Bewegung, die in vier charakteristische Phasen unterteilt werden kann. Ausgangspunkt ist der **Abbildung 45** folgend die Position (1), an der die Platine aufgenommen wird, während der Transfer in Warteposition steht. Danach wird über die Position (2) die Transportbewegung zur nächsten Pressenstufe durchgeführt. An der Position (3) kommt der Transfer erneut zum Stillstand. Hier wird die aufgenommene Platine an die nachfolgende Pressenstufe übergeben. Nach dieser kurzen Haltezeit verfährt der Transfer über die Rücklaufbahn (4) zurück in die Position (1), womit der Arbeitszyklus abgeschlossen ist. Dieser Vorgang wiederholt sich synchron zur vollständigen Umdrehung der Kurbelwelle und bildet den Grundrhythmus der Pressenlinie. Da die Bewegungsabfolge und die Stillstandsphasen des Transfers unmittelbar mit der Kurbelwellenrotation korrelieren, lässt sich hypothetisch annehmen, dass diese zyklische Bewegungskennlinie auch in den Sensordaten der Druckluftsysteme sichtbar wird. Insbesondere in den erfassten Druck- und Volumenstromverläufen sollten sich wiederkehrende Muster in Abhängigkeit der Kurbelwellenposition erkennen lassen. Diese Hypothese bildet die Grundlage für die anschließende datenanalytische Untersuchung, in der geprüft wird, ob die Sensorcharakteristik des Druckluftsystems die physikalische Transferbewegung zuverlässig abbildet und damit zur Ableitung des Prozesszustands herangezogen werden kann.

Insgesamt gewährleistet dieser Aufbau eine präzise Synchronisation zwischen dem mechanischen Bewegungsablauf des Transfers und der pneumatischen Steuerung. Das zeitlich abgestimmte Zusammenspiel von Ansaugen, Halten und Abblasen bildet die Grundlage




Abbildung 45: Bewegungsablauf Transfer

für eine reproduzierbare Werkstückübergabe und beeinflusst maßgeblich den Druckluftverbrauch des Gesamtsystems. Gleichzeitig ergibt sich hieraus die Möglichkeit, die Effizienz und den Zustand des Systems datenanalytisch zu überwachen, da die charakteristischen Druckverläufe in den Sensordaten unmittelbar mit den jeweiligen Phasen der Ejektorfunktion korrelieren.

Zur räumlichen Verortung der Sensorik entlang der Pressenlinie zeigt **Abbildung 46** die Positionen der Messstellen innerhalb des betrachteten Systems. Zwischen den sieben Pressstufen sind insgesamt 16 Druck- und Volumenstromsensoren (L1–L16) verbaut, die den Druckluftverbrauch sowohl auf der rechten als auch auf der linken Balkenseite erfassen. Die Anordnung ermöglicht eine stufenspezifische Zuordnung des Druckluftverbrauchs zu den jeweiligen Transferbewegungen und erlaubt die differenzierte Analyse von Seiten- und Stufenabweichungen. Zusätzlich werden über weitere Messpunkte der Luftdruck der Kompressoren, der Gesamtluftverbrauch der Anlage, der Luftdruck im Auslaufband, sowie die Drehzahl der Antriebswelle der Presse aufgezeichnet. Diese ergänzenden Messgrößen bilden die Grundlage, um die pneumatischen Zustandsgrößen mit den mechanischen Bewegungsdaten der Pressenlinie zu korrelieren. Damit kann der Zusammenhang zwischen Transferbewegung, Prozessphase und Druckluftbedarf quantifiziert werden.




Abbildung 46: Sensorplan Pressenlinie

(2) Datenvorbereitung. Die im Rahmen der Druckluftgreiferanalyse genutzten Sensordaten werden direkt aus der in der Produktionsumgebung implementierten intelligenten Data Pipeline gewonnen. Innerhalb dieser Kommunikationskette werden, wie in **Kapitel 6.3.2** erläutert, auf der Ebene des CMS X-Tools eine physische Schnittstelle integriert, über die ein lokales Speichermedium (HDD) als Zwischenspeicher fungiert. Über diese Schnittstelle werden für die Data-Mining-Anwendung in Bezug auf den Druckluftgreifer relevanten Daten abgelegt. Die Speicherung erfolgt in fest definierten Zeitintervallen, die sich am Presentakt orientieren und eine hinreichend hohe zeitliche Auflösung zur Abbildung der zyklischen Bewegungen des Greifers gewährleisten. Dadurch wird eine verlustarme Erfassung des Druckluftverbrauchs während der Saug- und Abblasephasen ermöglicht. Im betrachteten Fall wurden Daten aus dem Zeitraum 04.02.2021 bis zum 08.03.2021 gespeichert. Das Datenlogging erfolgt im proprietären X-Tools-Format (*.xts*), wobei jeweils zwölfminütige Datenpakete mit Nanosekunden-Zeitstempeln erzeugt werden. Diese werden automatisiert auf der angeschlossenen HDD persistiert und bilden somit den Ausgangspunkt der nachgelagerten Datenverarbeitung innerhalb der Data Pipeline.

Im Anschluss an die automatisierte Datenerfassung auf der X-Tools-Ebene erfolgt die Weiterverarbeitung der Messdaten im Rahmen eines ETL-Prozesses, dessen konzeptioneller Ablauf in **Kapitel 5.3** detailliert beschrieben ist, wobei die operative Umsetzung der durch den Verfasser vorgegebenen Verarbeitungsschritte im Rahmen der fachlich betreuten Masterarbeit unterstützt wurde [vgl. Jericho 2022, S.39-41]. Zunächst werden die auf der HDD gespeicherten *.xts*-Dateien aus dem X-Tools-System extrahiert. Aufgrund des proprietären Formats erfolgt die Datenentnahme über den X-Tools-Client, der die Signale in Sekundenintervallen exportiert und in das weiterverarbeitbare CSV-Format konvertiert. Dabei ist die Zeitauflösung durch die Messsoftware vorgegeben und auf Intervalle von jeweils zwölf Minuten pro Datei begrenzt. Insgesamt entstehen so über 81.675 Einzeldateien, die jeweils die Messwerte eines Sensors für den genannten Zeitraum enthalten. Der für die Datenmenge benötigte Speicherplatz beläuft sich auf 243 GB. Die erste Spalte jeder CSV-Datei enthält den vollständigen Zeitstempel im Format *date:time.nanoseconds* und gewährleistet somit eine eindeutige zeitliche Zuordnung aller Datensätze. Um das Datenvolumen und die Konvertierungsdauer zu reduzieren, wird die ursprüngliche Abtastrate von 100 Hz auf 10 Hz herabgesetzt. Diese Reduktion senkt die Datenmenge signifikant, ohne die Aussagekraft der zyklischen Druckluftverläufe zu beeinträchtigen [vgl. Jericho 2022, S.39-40; Evirgen und Wartenberg 2024, S.5-6]. Anschließend werden sämtliche CSV-Dateien sensorweise über ein Python-Skript eingelesen und auf Basis der Zeitstempel zusammengeführt. Das resultierende Gesamt-DataFrame umfasst mehr als 23 Millionen Zeilen und 26 Spalten mit einem Speicherbedarf von etwa 4,7 GB [vgl. Jericho 2022, S.40]. Zur performanten Zwischenspeicherung wurde das aggregierte DataFrame im Pickle-Format abgelegt. Das Pickle-Format bietet gegenüber CSV- oder Parquet-Dateien den Vorteil, dass sämtliche Python-spezifischen Datentypen verlustfrei serialisiert und beim erneuten Laden ohne Typkonvertierungen rekonstruiert werden können [vgl. McKinney 2022, S.183-185]. Dies ist insbesondere für große Zwischenstände im ETL-Prozess relevant, da damit nicht nur der Lese-/Schreib-Aufwand deutlich reduziert, sondern auch die Konsistenz komplexer Zwischen-DataFrames erhalten bleibt.

Die aufgezeichneten Variablen enthalten die in der **Tabelle 12** dargestellten Sensornamen, Beschreibungen und Datentypen [vgl. Jericho 2022, S.40]. Wie in **Abbildung 46** dargestellt, werden neben den Druckluftverbrauchswerten der sechzehn Druckluftsensoren auch Hilfsgrößen wie Zeitstempel und Pressenposition aufgenommen. Diese vollständige Zusammenführung ermöglicht erstmals eine integrierte Betrachtung des Druckluftsystems über alle relevanten Baugruppen der Presse hinweg und bildet die Grundlage für die anschließende Transformations- und Modellierungsphase.

Tabelle 12: Übersicht Sensorsignale Druckluftgreifer-Fallstudie

Sensorname	Beschreibung	Datentyp
Zeitstempel	Tag und Zeit Sensorwert	string
EOL_L15_Luftverbrauch	Druckluftverbrauch hinten (Sensor 15)	integer
FOL_L16_Luftverbrauch	Druckluftverbrauch vorne (Sensor 16)	integer
T1_L01_Luftverbrauch_r	Transfer 1 Druckluftverbrauch rechts (Sensor 1)	integer
T1_L02_Luftverbrauch_l	Transfer 1 Druckluftverbrauch links (Sensor 2)	integer
T2_L03_Luftverbrauch_r	Transfer 2 Druckluftverbrauch rechts (Sensor 3)	integer
T2_L04_Luftverbrauch_l	Transfer 2 Druckluftverbrauch links (Sensor 4)	integer
T3_L05_Luftverbrauch_r	Transfer 3 Druckluftverbrauch rechts (Sensor 5)	integer
T3_L06_Luftverbrauch_l	Transfer 3 Druckluftverbrauch links (Sensor 6)	integer
T4_L07_Luftverbrauch_r	Transfer 4 Druckluftverbrauch rechts (Sensor 7)	integer
T4_L08_Luftverbrauch_l	Transfer 4 Druckluftverbrauch links (Sensor 8)	integer
T5_L09_Luftverbrauch_r	Transfer 5 Druckluftverbrauch rechts (Sensor 9)	integer
T5_L10_Luftverbrauch_l	Transfer 5 Druckluftverbrauch links (Sensor 10)	integer
T6_L11_Luftverbrauch_r	Transfer 6 Druckluftverbrauch rechts (Sensor 11)	integer
T6_L12_Luftverbrauch_l	Transfer 6 Druckluftverbrauch links (Sensor 12)	integer
T7_L13_Luftverbrauch_r	Transfer 7 Druckluftverbrauch rechts (Sensor 13)	integer
T7_L14_Luftverbrauch_l	Transfer 7 Druckluftverbrauch links (Sensor 14)	integer
Antriebswelle_Hubzahl	Drehzahl Antriebswelle [Umdrehungen/min]	double
Luftdruck_Auslaufband	Druckluft Auslaufband	integer
Luftdruck_Einleger	Druckluft Einleger	integer
Luftdruck_Kompressoren	Druckluft Kompressoren	integer
Luftverbrauch_10bar	Druckluftverbrauch 10bar System	integer
Luftverbrauch_15bar	Druckluftverbrauch 15bar System	integer
Luftverbrauch_Anlage	Druckluftverbrauch Gesamtanlage	integer
Pressenposition	Kurbelwellenposition [°]	integer
Werkzeugnummer	Nummer des eingesetzten Werkzeuges	integer

Im weiteren Verlauf wurden die Rohdaten auf technische Plausibilität und Vollständigkeit geprüft. Die Ziele und Prüfkriterien der Datenbereinigung wurden durch den Verfasser vorgegeben. Die technische Umsetzung der nachfolgend beschriebenen Schritte wurde im Rahmen der betreuten Masterarbeit dokumentiert [vgl. ebd., S.40-41].

Dabei zeigte sich, dass die Druck- und Verbrauchswerte der 10- und 15-bar-Systeme sowie die Kompressordrücke teilweise negative Werte enthielten, die physikalisch nicht plausibel waren. Da mehr als 50 % der betreffenden Werte unplausibel waren, wurden diese Spalten von der weiteren Analyse ausgeschlossen. Die verbleibenden Sensorkanäle wurden auf technisch plausible Wertebereiche geprüft. Die zunächst als Zeichenketten vorliegenden Zeitstempel wurden in das standardisierte *datetime*-Format überführt und zeitlich synchronisiert. Nicht benötigte Variablen, darunter die Drehzahl der Antriebswelle, wurden für die nachfolgende Modellierung entfernt. Zur besseren Übersicht wurden die Druckluftsensoren entsprechend ihrer Anlagenposition in L1–L16 umbenannt. Die ab-

schließende Prüfung auf fehlende Werte (*NaN*) ergab für den bereinigten Datensatz keine Lücken, sodass keine Interpolation erforderlich war. Ein Ausschnitt des resultierenden Datensatzes ist in **Abbildung 47** dargestellt.

Zeitstempel	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12	L13	L14	L15	L16	Pressenposition	Werkzeugnummer
2021-02-04 14:21:38.500	0	0	1	1.0	3.0	1.0	8.0	4.0	2.0	0.0	1.0	0.0	2.0	0.0	4.0	78.0	54.0	10.0
2021-02-04 14:21:38.600	0	0	1	1.0	3.0	1.0	8.0	4.0	2.0	0.0	1.0	0.0	2.0	0.0	4.0	78.0	55.0	10.0
2021-02-04 14:21:38.700	0	1	0	1.0	3.0	1.0	8.0	4.0	2.0	0.0	1.0	0.0	2.0	0.0	3.0	78.0	56.0	10.0
2021-02-04 14:21:38.800	0	1	0	1.0	3.0	1.0	8.0	4.0	2.0	0.0	1.0	0.0	2.0	0.0	3.0	78.0	57.0	10.0
2021-02-04 14:21:38.900	0	1	0	0.0	3.0	1.0	8.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	3.0	78.0	59.0	10.0
2021-02-04 14:21:39.000	0	1	0	0.0	3.0	1.0	8.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	3.0	78.0	61.0	10.0
2021-02-04 14:21:39.100	0	1	0	0.0	3.0	1.0	8.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	2.0	79.0	63.0	10.0
2021-02-04 14:21:39.200	0	1	0	0.0	3.0	1.0	8.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	2.0	79.0	65.0	10.0
2021-02-04 14:21:39.300	0	1	0	0.0	4.0	2.0	9.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	3.0	78.0	67.0	10.0
2021-02-04 14:21:39.400	0	1	0	0.0	4.0	2.0	9.0	4.0	2.0	0.0	0.0	0.0	2.0	0.0	3.0	78.0	69.0	10.0

Abbildung 47: Ausschnitt bereinigter Datensatz

(3) Modellierung und Ergebnisinterpretation. Im Rahmen der Modellierungsphase erfolgt zunächst die explorative Datenanalyse, um ein grundlegendes Verständnis für Struktur, Qualität und Zusammenhänge der im vorhergehenden ETL-Prozess erzeugten Sensordaten zu gewinnen. Ziel dieser Phase ist es, charakteristische Muster des Druckluftverbrauchs während der Produktionszyklen zu identifizieren, erste Hypothesen über Zusammenhänge zwischen Prozessparametern und Verbrauchsverhalten abzuleiten sowie potenzielle Anomalien sichtbar zu machen.

Zu diesem Zweck wurde ein repräsentativer Ausschnitt der ersten 3.000 Datenpunkte aller sechzehn Druckluftsensoren über den aufgezeichneten Zeitverlauf visualisiert [vgl. Jericho 2022, S.41-43; Evirgen und Wartenberg 2024, S.6]. Eine vollständige Darstellung aller über 23 Millionen Datenpunkte wäre aufgrund des Datenvolumens weder interpretierbar noch effizient darstellbar. Die zusammenfassend in der **Abbildung 48** erzeugten Plots zeigen deutlich die zyklische Charakteristik der Zeitreihen, die durch den periodischen Bewegungsablauf des Druckluftgreifers bestimmt ist [vgl. Jericho 2022, S.42; Evirgen und Wartenberg 2024, S.6]. Die Pressenposition steigt dabei in einem gleichförmigen Verlauf von 0° auf 360° und fällt anschließend wieder auf 0°, was einem vollständigen Hubzyklus entspricht. Innerhalb dieses Zyklus schwankt der Druckluftverbrauch in charakteristischen Mustern, die den Ansaug- und Abblasephasen des Greifers entsprechen. Auffällig ist, dass der Druckluftverbrauch je nach Sensor deutlich variiert. So zeigt insbesondere der Sensor L16 über den gesamten Aufzeichnungszeitraum einen signifikant höheren Luftverbrauch als die übrigen Sensoren. Diese Beobachtung weist auf unterschiedliche Funktionslasten der Transfers hin und unterstreicht die Notwendigkeit einer sensor- und werkzeugspezifischen Analyse. Darüber hinaus lassen sich in den Zeitreihen Phasen erkennen, in denen sich die Pressenposition über mehrere Zeitschritte hinweg nicht ändert. Diese Phasen repräsentieren Stillstände oder Unterbrechungen des Produktionsablaufs. Während dieser Stillstände bleibt der Druckluftverbrauch einzelner Sensoren (z. B. L5, L9, L11, L16) auf einem konstant erhöhten Niveau, was auf Leckagen oder ineffiziente Dichtungen hinweisen kann.

Zur weiteren Differenzierung wurden die Druckluftverläufe nach den jeweiligen Werkzeugen segmentiert, die in der Sensorliste codiert wiederzufinden sind. Insgesamt wurden




Abbildung 48: Ausgabe ersten 3000 Datenpunkte

während des Aufzeichnungszeitraums sechzehn unterschiedliche Werkzeugsätze eingesetzt. Die Analyse des mittleren Druckluftverbrauchs pro Werkzeug und Sensor auf Basis der Plots, die in der **Abbildung 64** im **Anhang F** zu sehen sind, zeigt signifikante Unterschiede in den Verbrauchsprofilen. Diese Unterschiede lassen sich auf werkzeugspezifische Bewegungsprogramme und abweichende Steuerparameter der Ejektoren zurückführen. Nach Rücksprache mit dem Instandhaltungspersonal wurde bestätigt, dass für jedes Werkzeug individuelle Parameter für das Ansaugen und Ablegen der Platinen an der Anlagensteuerung hinterlegt sind. Aus der explorativen Analyse lassen sich mehrere Erkenntnisse ableiten:

1. Der Druckluftverbrauch folgt einem stark zyklischen Verlauf, der mit dem Pressenhub korreliert.
2. Werkzeugspezifische Parameter beeinflussen das Verbrauchsverhalten signifikant und müssen in der weiteren Modellierung berücksichtigt werden.
3. Das Auftreten konstanter Verbrauchswerte während Stillstandsphasen deutet auf energetische Verluste durch Leckagen hin.
4. Eine rein globale Modellierung ohne Kontextparameter (z.B. Werkzeugnummer, Pressenposition) würde die physikalische Heterogenität der Daten nicht adäquat abbilden.

Im Rahmen der vorbereitenden Analyseschritte wurde zunächst eine deskriptive und statistische Auswertung der Druckluftverbräuche durchgeführt, um die Charakteristik der einzelnen Werkzeugsätze zu verstehen und eine empirische Grundlage für die nachfolgenden modellbasierten Verfahren zu schaffen. Im Gegensatz zu korrelativen Untersuchungen zwischen Sensoren, die keine wechselseitige Abhängigkeit aufweisen, liegt der Fokus dieser Analyse auf der inneren Struktur der Verbrauchsdaten je Werkzeugkonfiguration. Jedes Werkzeug besitzt in der Anlage eine spezifische Parametrierung der Ventile, Taktzeiten und Ejektorsteuerungen, wodurch sich charakteristische Verbrauchsprofile ausbilden. Diese individuellen Profile sind maßgeblich durch die physikalische Auslegung des Werkzeugs und den zugehörigen Bewegungsablauf während des Pressenzyklus bestimmt.

Zur quantitativen Beschreibung wurden für den Werkzeugsatz 10 die zentralen statistischen Kennwerte berechnet: das arithmetische Mittel als Maß für den durchschnittlichen Druckluftverbrauch, die Standardabweichung zur Erfassung der Streuung, der Interquartilsabstand (IQR) als robustes Maß für die Spannweite der mittleren 50 % der Werte sowie die Quantile (Q_1 , Median, Q_3) zur Identifikation von Symmetrie und Ausreißertendenzen in der Verteilung (vgl. **Anhang 63**). Zur Verdeutlichung der zuvor beschriebenen statistischen Vorgehensweise wird im Folgenden die Ausreißeranalyse exemplarisch am Sensor L1 des Werkzeugs 10 näher erläutert. Dieser Sensor erfasst den Druckluftverbrauch an der vorderen Transferachse und ist damit repräsentativ für das zyklische Ansaug- und Abblasseverhalten des Greifers. Die Untersuchung wurde auf Basis von gleitenden Mittelwerten über Zeitfenster von zehn Sekunden durchgeführt, um kurzzeitige Messrauschanteile zu glätten und den zyklischen Verbrauchsverlauf deutlicher sichtbar zu machen.

Die **Abbildung 49** zeigt die Auswertung mittels Dreifacher Standardabweichung (3σ -Methode). Hier wurde der Mittelwert $\bar{x}$ (grün gestrichelt) als Referenzgröße gewählt, während die roten Linien die Grenzwerte bei $\bar{x} \pm 3\sigma$ abbilden. Auch hier ist ersichtlich, dass der überwiegende Teil der Messwerte innerhalb des definierten Bereichs liegt, während wiederkehrende Verbrauchsspitzen deutlich oberhalb der $+3\sigma$ -Grenze auftreten.




Abbildung 49: Ausreißeranalyse mittels 3σ -Methode

In der **Abbildung 50** sind die Ergebnisse der IQR-Analyse zu sehen. Die durchgezogene orangefarbene Linie stellt den zeitlichen Verlauf des Druckluftverbrauchs dar, während die gestrichelten Linien die Quartile Q_1 und Q_3 markieren. Die roten Linien kennzeichnen die obere und untere IQR-Grenze, die nach der Regel $Q_3 + 1,5 \cdot IQR$ bzw. $Q_1 - 1,5 \cdot IQR$ berechnet wurden. Innerhalb des markierten Intervalls (rot schattierte Fläche) befinden sich etwa 95 % der Messwerte.

Die auf Basis dieser Kennwerte durchgeführte Ausreißeridentifikation verdeutlicht, dass die Verbrauchsdaten keine stationäre Grundverteilung aufweisen, sondern stark zeit- und zyklusabhängig sind. Einzelne Verbrauchsspitzen treten regelmäßig innerhalb des Pressenzyklus auf und lassen sich ohne Berücksichtigung der Pressenposition kaum von technischen Fehlzuständen unterscheiden. Damit wird deutlich, dass statische Schwellenwerte zur Überwachung des Druckluftverbrauchs in diesem Anwendungskontext wenig Aussagekraft be-




Abbildung 50: IQR-Ausreißeranalyse des Druckluftverbrauchs

sitzen. Ein konstanter Grenzwert kann aufgrund der stark variierenden Verbrauchsmuster der einzelnen Werkzeuge weder prozessspezifische Effekte noch reale Anomalien zuverlässig trennen. Aus der statistischen Analyse lässt sich somit die zentrale These ableiten, dass eine isolierte Betrachtung der Verbrauchswerte ohne Bezug zur physikalischen Pressenbewegung nicht geeignet ist, den Zustand des Druckluftsystems zu bewerten. Erst durch die Verknüpfung der Druckluftverbräuche mit den Prozessgrößen des Umformzyklus, wie der Pressenposition oder dem Bewegungsverlauf des Hubs, lässt sich ein kontextsensitives Modell zur Erkennung von Abweichungen realisieren. Für das betrachtete Werkzeug ist der mittlere Luftverbrauch je Sensor über die Pressenposition in der **Abbildung 64** im **Anhang F** zu sehen.

Die zuvor durchgeführte statistische Analyse hat gezeigt, dass sich der Druckluftverbrauch der einzelnen Sensoren nicht direkt miteinander vergleichen lässt. Jeder Sensor arbeitet unabhängig von den übrigen und ist einem spezifischen Werkzeug mit individuellen Einstellparametern zugeordnet. Ebenso unterscheiden sich die Verbrauchsverläufe der Werkzeugsätze aufgrund ihrer jeweiligen Bewegungsprogramme und Ventilsteuerungen deutlich voneinander. Ein direkter Vergleich des absoluten Druckluftverbrauchs zwischen den Sensoren oder Werkzeugen ist daher nicht zielführend. Um dennoch charakteristische Muster innerhalb des Verbrauchsverlaufs erkennen zu können, ist eine Transformation der Zeitreihendaten in zyklusbasierte Strukturen erforderlich. Grundlage dieser Transformation bildet die physikalische Bewegung der Presse, deren Kurbelwelle während eines vollständigen Umformhubs einen Bereich von 0 bis 360 durchläuft. Dieser Verlauf dient als periodische Referenz, anhand derer die kontinuierlich aufgezeichneten Druckluftverbrauchsdaten segmentiert werden. Für die exemplarische Analyse wurde, analog zur statistischen Auswertung, Sensor L1 des Werkzeugs mit der Nummer 10 ausgewählt [vgl. Jericho 2022, S.44; Evirgen und Wartenberg 2024, S.6]. Dieses Werkzeug wurde im untersuchten Zeitraum am häufigsten eingesetzt und repräsentiert damit eine hinreichend große Datenbasis. Die Segmentierung erfolgt, indem die Zeitreihe jedes Mal, wenn die Pressenposition 360 erreicht, unterbrochen und die zugehörigen Sensorwerte als separater Zyklus gespeichert werden. Somit entsteht ein Datensatz, in dem jede Zeile einem vollständigen Pressenhub entspricht

und die Spalten die einzelnen Messpunkte innerhalb dieses Zyklus repräsentieren.

Die **Abbildung 51** veranschaulicht diesen Transformationsprozess. Der kontinuierliche Signalverlauf wird dabei in einzelne, sich wiederholende Prozesszyklen überführt. In der Praxis wurden auf diese Weise 26.857 vollständige Zyklen identifiziert und extrahiert [vgl. Jericho 2022, S.44; Evirgen und Wartenberg 2024, S.6]. Die Pressenposition, zu der jeder Messwert aufgezeichnet wurde, stellt bereits eine erste Form eines Merkmals dar, da sie den Verbrauchswert einem konkreten Abschnitt des Umformprozesses zuordnet. Da die Messfrequenz der ursprünglichen Zeitreihe 10 Hz beträgt und die Presse im Mittel zehn Hübe pro Minute ausführt, entstehen beim Umwandeln der kontinuierlichen in zyklische Datenstrukturen teilweise fehlende Werte (NaN). Diese treten immer dann auf, wenn nicht für jeden Zyklus exakt dieselbe Anzahl an Abtastpunkten vorliegt. Solche unvollständigen Datenreihen können die Stabilität vieler Modellierungsverfahren beeinträchtigen. Daher erfolgt im nächsten Schritt (*Feature Engineering*) die Erzeugung neuer, aggregierter Merkmale je Zyklus, um die unvollständigen Sequenzen in eine konsistente Form zu überführen und zugleich aussagekräftige Kennwerte für die nachfolgende Modellierung zu gewinnen.

L1	Pressenposition	Zyklus	1	2	3	4	5	6	7	8	...	355	356	357	358	359	360
5	1	1	5	NaN	NaN	14	NaN	NaN	17	NaN	...	NaN	4	NaN	NaN	2	NaN
14	4																
17	7																
...	...																
4	356	2	NaN	6	NaN	NaN	15	NaN	NaN	17	...	5	NaN	NaN	1	NaN	NaN
2	359																
6	2																
15	5																
17	8	...															
...	...																
5	355																
1	358																
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...

Abbildung 51: Transformation der Zeitreihendaten in Pressenzyklen

Aufbauend auf der zuvor beschriebenen Transformation der kontinuierlichen Zeitreihendaten in zyklusbasierte Datensätze erfolgt im nächsten Schritt die Merkmalerzeugung (*Feature Engineering*) [vgl. Jericho 2022, S.45-47]. Ziel dieser Phase ist es, aus den segmentierten Sensordaten aussagekräftige Kennwerte zu extrahieren, die eine quantitative Beschreibung des Druckluftverbrauchs innerhalb eines vollständigen Pressenhubs ermöglichen und damit eine fundierte Grundlage für die nachfolgende Modellierung bilden.

Wie in **Abbildung 52** dargestellt, wird jeder Zyklus in einen Merkmalsvektor überführt [vgl. ebd., S.45]. Dabei entspricht jede Zeile der resultierenden Feature-Matrix einem Pressenzyklus und jede Spalte einem berechneten Merkmal. Diese Merkmale charakterisieren den Verlauf des Druckluftverbrauchs entlang der Pressenposition (0° – 360°) und verdichten die Rohdaten in eine kompakte, modellierbare Form.

Die wichtigsten aus den Zyklusverläufen extrahierten Merkmale sind in **Abbildung 53** visualisiert und lassen sich wie folgt zusammenfassen [vgl. ebd., S.46]:

- **Arithmetisches Mittel ($\bar{x}$):** beschreibt den durchschnittlichen Druckluftverbrauch pro Zyklus und dient als Maß für den Basisverbrauch. Ein erhöhter Mittelwert kann auf ineffiziente Ventilsteuerungen oder dauerhafte Leckagen hinweisen.

Zyklus	1	2	3	4	5	6	7	8	...		Zyklus	Feature 1	Feature 2	Feature 3	...
1	5	NaN	NaN	14	NaN	NaN	17	NaN	...	→	1				...
2	NaN	6	NaN	NaN	15	NaN	NaN	17	...	→	2				...
...	...	...	...	...	...	...	...	...	...		...	...	...	...	...

Abbildung 52: Feature Extraction

- **Standardabweichung (s) und Varianz (s^2):** quantifizieren die Streuung der Verbrauchswerte innerhalb eines Zyklus und ermöglichen Rückschlüsse auf die Prozessstabilität. Ein hoher Streuwert deutet auf unregelmäßige Taktungen oder unstetige Druckregelungen hin.
- **Median ($\tilde{x}$):** fungiert als robustes Lagemaß gegenüber Ausreißern und unterstützt die Erkennung asymmetrischer Verteilungen.
- **Globales Maximum und Minimum:** kennzeichnen die Extremwerte des Druckluftverbrauchs, welche die maximalen Ansaug- bzw. Abblasephasen sowie die Ruheabschnitte abbilden.
- **Anzahl und Position lokaler Maxima (Peaks):** beschreiben die charakteristischen Druckspitzen, die beim Ansaugen und Abblasen der Platine auftreten. Abweichungen in Anzahl oder Lage der Peaks können auf Anomalien im Ablauf der Venturidüsen hinweisen.
- **Fläche unter der Kurve (Integral):** stellt den Gesamtluftverbrauch pro Zyklus dar und erlaubt eine Bewertung der energetischen Effizienz sowie einen Vergleich zwischen Werkzeugen und Sensoren.




Abbildung 53: Ausgewählte Merkmale

Die Form und Position der Peaks sind direkt an den physikalischen Ablauf des Druckluftsystems gekoppelt. Zu Beginn jedes Pressenzyklus (etwa zwischen 0 und 110) steigt

der Druckluftverbrauch steil an, da die Venturidüsen den notwendigen Unterdruck zum Ansaugen der Platine erzeugen. Sobald das Vakuum aufgebaut ist, stabilisiert sich der Verbrauch kurzzeitig, bevor im Bereich von 240 bis 270 ein zweiter signifikanter Peak auftritt, der dem Abblasen beim Ablegen der Platine entspricht. Zwischen diesen beiden Peaks ist typischerweise eine Verbrauchssenke zu erkennen, die die Ruhephase zwischen Ansaug- und Abblasvorgang markiert (vgl. **Abbildung 53**). Dieser charakteristische Verlauf kann physikalisch durch das Wirkprinzip der Kompaktejektoren erklärt werden. Während des Ansaugvorgangs wird Druckluft in einer Düse beschleunigt, wodurch gemäß dem Venturi-Prinzip ein Unterdruck entsteht, der die Platine anhebt. Nach erfolgreichem Transport wird der Unterdruck gezielt abgelassen und durch eine Druckimpulsphase (Abblasen) ersetzt, um das Werkstück wieder abzulegen. Das resultierende Druckluftprofil zeigt daher zwei wiederkehrende Verbrauchsspitzen pro Zyklus, die in ihrer Höhe und zeitlichen Position unmittelbar mit dem Werkzeugzustand und der Taktfrequenz der Presse verknüpft sind. Abweichungen von diesem typischen Muster können auf fehlerhafte Prozesszustände hinweisen. Fehlt beispielsweise die charakteristische Verbrauchssenke zwischen den beiden Peaks, deutet dies auf ein unvollständiges Entlüften des Systems hin. Eine dauerhaft hohe Grundlast signalisiert dagegen Undichtigkeiten oder falsch eingestellte Ventile. Auch eine Verschiebung der Peak-Positionen weist auf Änderungen in der Ventilsteuerung oder auf unterschiedliche Werkzeugkonfigurationen hin. Zur Validierung der Merkmalsauswahl wurde das Fachwissen des Instandhaltungspersonals einbezogen, das über langjährige Erfahrung im Betrieb und in der Wartung pneumatischer Systeme verfügt. Diese Experten bestätigten, dass insbesondere die Fläche unter der Kurve, die Anzahl der Peaks und deren Positionen entscheidende Indikatoren für die Beurteilung des Systemzustands darstellen. Die Kombination dieser Kennwerte erlaubt die Unterscheidung zwischen prozessbedingten Schwankungen und echten Anomalien, wie etwa Vakuumverlusten oder fehlerhaften Schaltvorgängen der Ejektoren. Das extrahierte Merkmalsset stellt somit eine strukturierte, physikalisch interpretierbare Verdichtung der Druckluftdaten dar. Es reduziert die Datenmenge pro Zyklus erheblich, erhält jedoch die charakteristischen Prozesssignaturen. Dadurch bildet es eine robuste Grundlage für die anschließende Anwendungen, mit denen sich die typischen Verbrauchsmuster der Werkzeuge datengetrieben clustern und Abweichungen potenziell automatisiert erkennen lassen.

Nach der statistischen Betrachtung sowie erfolgreichen Aufbereitung und Merkmalsextraktion der Sensordaten folgt die Modellierungsphase, in der geeignete Verfahren zur Identifikation von Anomalien im Druckluftverbrauch entwickelt und angewendet werden. Ziel dieser Phase ist es, Muster im zyklischen Verbrauchsverhalten zu erkennen, die auf sich anbahnende Fehlfunktionen oder ineffiziente Zustände innerhalb des pneumatischen Systems hinweisen.

Das übergeordnete Ziel der Modellierung orientiert sich an der ganzheitlichen Zielsetzung der vorliegenden Arbeit, mittels der Umsetzung von Algorithmen, die in einer intelligenten Data Pipeline eingebettet sind, konkrete Ergebnisse hinsichtlich der Fehlfunktion von Anlagenkomponenten zu liefern und das Instandhaltungspersonal durch Handlungsempfehlungen zu unterstützen. Unerwünschte oder kritische Zustände sollen nicht erst im Störfall erkannt, sondern anhand datengetriebener Abweichungen frühzeitig vorhergesagt

werden. In einem Prozess, der wie im vorliegenden Fall zyklisch und weitgehend gleichförmig abläuft, ist davon auszugehen, dass sich Anomalien wiederkehrender Muster unmittelbar auf den Systemzustand auswirken. Je höher die Häufigkeit solcher Anomalien im Zeitverlauf, desto größer ist die Wahrscheinlichkeit, dass eine Störung oder ein Ausfall bevorsteht. Eine Anomalie im Druckluftverbrauch wird definiert als eine statistisch signifikante Abweichung des aktuellen Messwertverlaufs vom erwarteten Verbrauchsprofil, das durch die vorangehend extrahierten Merkmale charakterisiert wird. Diese Abweichungen können sich sowohl in der Höhe einzelner Spitzen, in deren zeitlicher Position, als auch in der Form des gesamten Zyklusverlaufes äußern. Für die Druckluftgreifer-Fallstudie werden im Folgenden die Ansätze Maximum Mean Discrepancy (MMD), überwachte Klassifikationsalgorithmen sowie unüberwachte Clusteralgorithmen für den Sensor L1 des Werkzeuges mit der Nummer 10 angewendet.

Im ersten Schritt der Modellierungsphase wurde die **Maximum Mean Discrepancy (MMD)** als Ähnlichkeitsmaß eingesetzt, um Unterschiede zwischen den Druckluftverbrauchszyklen quantitativ zu bewerten (vgl. **Kapitel 3.3.3**; [vgl. Jericho 2022, S.47-48]). Die MMD bietet einen robusten Ansatz zur Bestimmung der Distanz zwischen zwei Wahrscheinlichkeitsverteilungen und eignet sich damit besonders zur Erkennung von Verteilungsänderungen in zyklischen Prozessdaten [vgl. Gretton et al. 2012, S.724-729]. Während klassische Kennzahlen, wie Mittelwert oder Standardabweichung, lediglich einzelne Aspekte einer Verteilung beschreiben, berücksichtigt die MMD die Gesamtdifferenz zweier Verteilungen im Feature-Raum. Dabei wird das Erkennen von Abweichungen in den aus dem Feature Engineering erzeugten Merkmalsvektoren zwischen verschiedenen Pressenzyklen angestrebt. Diese Vektoren beinhalten unter anderem statistische Größen (Mittelwert, Varianz, Median) sowie prozessspezifische Merkmale wie Peak-Lage, Peak-Höhe und Integralfläche.

Zur Berechnung wird die MMD wie folgt definiert:

$$\text{MMD}^2[\mathcal{F}, X, Y] = \frac{1}{m^2} \sum_{i,j=1}^m k(x_i, x_j) + \frac{1}{n^2} \sum_{i,j=1}^n k(y_i, y_j) - \frac{2}{mn} \sum_{i=1}^m \sum_{j=1}^n k(x_i, y_j), \quad (1)$$

wobei $k(\cdot, \cdot)$ eine Kernel-Funktion ist. In dieser Arbeit wurde der **RBF-Kernel (Radial Basis Function)** eingesetzt:

$$k(x, y) = \exp \left(-\frac{\|x - y\|^2}{2\sigma^2} \right), \quad (2)$$

mit dem Glättungsparameter σ , der die Sensitivität gegenüber kleinen Abweichungen steuert. Der resultierende MMD-Wert gibt an, wie stark sich zwei Zyklen voneinander unterscheiden. Je kleiner der MMD-Wert, desto ähnlicher sind sich die Verbrauchsverteilungen, wobei hohe Werte dagegen auf strukturelle Abweichungen oder potenzielle Anomalien hindeuten. Für die Anwendung im vorliegenden Fall wurden die MMD-Werte aller Zyklen des Werkzeugs 10 auf Basis des Sensors L1 berechnet. Zur Festlegung eines Trennkriteriums zwischen *normalem* und *abweichendem* Verhalten wurde ein empirischer Schwellenwert (=0.00001) definiert. Alle Zyklen, deren MMD-Wert den Schwellenwert τ_{MMD} überschrit-

ten, wurden als Anomalien klassifiziert. Zur Bewertung der Klassifikationsgüte wurde die resultierende Zuordnung in einer Konfusionsmatrix dargestellt (vgl. **Abbildung 54**; [vgl. Jericho 2022, S.48]). Zur Klassifikation wurde ein statischer Schwellwert $\tau_{\text{MMD}} = 0.00001$ angesetzt: $\text{MMD} > \tau_{\text{MMD}} \Rightarrow \text{anomal}$, andernfalls *normal*. Die resultierende Konfusionsmatrix (Werkzeug 10, Sensor L1) ist in **Abbildung 54** dargestellt und liefert folgende Zählwerte:

- **Wahre Negative (TN)**: 651 normal korrekt als normal klassifiziert,
- **Falsch Positive (FP)**: 13 normal fälschlich als anomal klassifiziert,
- **Falsch Negative (FN)**: 61 anomal nicht erkannt,
- **Wahre Positive (TP)**: 176 anomal korrekt erkannt.

Damit ergeben sich bei insgesamt $N = 901$ Zyklen die Kennzahlen:

$$\text{Accuracy} = \frac{TP + TN}{N} = \frac{176 + 651}{901} \approx 0.918, \quad \text{Precision} = \frac{TP}{TP + FP} = \frac{176}{176 + 13} \approx 0.931,$$

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{176}{176 + 61} \approx 0.743, \quad F_1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \approx 0.826.$$

Die Fehlerraten nach Klasse sind $\text{FPR} = \frac{FP}{FP+TN} \approx 1.96\%$ und $\text{FNR} = \frac{FN}{FN+TP} \approx 25.74\%$.

Die Ergebnisse zeigen, dass die MMD eine hohe Sensitivität gegenüber Formänderungen der Zykluskurve aufweist und anomale Zyklen mit hoher Präzision erkennt. Die vergleichsweise höhere FNR weist jedoch darauf hin, dass subtilere Anomalien, beispielsweise eine leicht verringerte Peak-Höhe bei unveränderter Position, mit dem gewählten Schwellenwert teilweise noch nicht erfasst werden. Dies motiviert im nächsten Schritt die Kombination mit weiteren Lernverfahren, die strukturelle Muster über mehrere Zyklen hinweg berücksichtigen.

Tatsächlicher Wert []	0	651	13
	1	61	176
		0	1
		Errechneter Wert []	

Abbildung 54: Konfusionsmatrix der MMD-Auswertung

Der zweite Ansatz der Modellierungsphase basiert auf der Anwendung überwachter Lernverfahren (*supervised classification*), die darauf abzielen, die zuvor extrahierten Merk-

malsvektoren den Klassen *normal* und *anomal* zuzuordnen [vgl. ebd., S.49-50]. Im Gegensatz zu unüberwachten Verfahren, die Strukturen im Datensatz selbständig erkennen, wird beim überwachten Lernen ein Trainingsdatensatz mit bekannten Zielwerten (*Labels*) verwendet, um ein Modell zu trainieren, das anschließend unbekannte Zyklen klassifiziert. Für diesen Schritt wird das im vorangegangenen Abschnitt erstellte Testdatenset wieder verwendet, das 901 Zyklen umfasst, von denen 237 als *anomal* und 664 als *normal* manuell gelabelt wurden. Die zuvor im Feature-Engineering gewonnenen Merkmale (arithmetisches Mittel, Varianz, Standardabweichung, Median, Maxima, Minima, Peak-Lagen und Fläche unter der Kurve) dienen als Eingabegrößen für die Klassifikationsalgorithmen. Die Implementierung erfolgt unter Verwendung der *Python scikit-learn*-Bibliothek, die eine Vielzahl gängiger Klassifikationsmodelle bereitstellt. Für die vorliegende Arbeit wurden mit **Logistic Regression (LR)**, **Support Vector Machine (SVM)**, **Naive Bayes (NB)**, **Stochastic Gradient Descent (SGD)**, **Linear Discriminant Analysis (LDA)**, **K-Nearest Neighbors (k-NN)** und **Decision Tree (DT)** sieben repräsentative Klassifikationsverfahren ausgewählt und im Hinblick auf ihre Klassifikationsgüte systematisch miteinander verglichen (vgl. **Kapitel 3.3.3**).

Zur Evaluierung der Modelle wird der Datensatz im Verhältnis von 70% Trainings- zu 30% Testdaten aufgeteilt. Die Güte der Modelle wird mittels 10-facher Kreuzvalidierung bestimmt, um eine robuste Aussage über die Generalisierungsfähigkeit zu ermöglichen. Als Hauptkennwert wird die mittlere *Accuracy* herangezogen, welche den Anteil korrekt klassifizierter Zyklen beschreibt. Die in **Tabelle 13** dargestellten Ergebnisse entsprechen der im Rahmen der studentischen Arbeit durchgeführten experimentellen Auswertung [vgl. Jericho 2022, S.49-50]. Sechs der sieben untersuchten Algorithmen erreichen eine mittlere *Accuracy* von mehr als 90 %. Die höchste *Accuracy* erzielt die logistische Regression mit 95,5 %, gefolgt von k-NN mit 95,2 % und dem Decision Tree mit 94,6 %. Der SGD-Klassifikator weist mit 70,4 % ein deutlich schwächeres Ergebnis auf. Eine mögliche Ursache liegt in der Sensitivität des Verfahrens gegenüber unterschiedlich skalierten Eingangsmerkmalen.

Tabelle 13: Erreichte Genauigkeitswerte der getesteten Klassifikationsalgorithmen

Klassifikationsalgorithmus	Accuracy [%]
Logistic Regression	95.5
Support Vector Machine	91.2
Naive Bayes	91.9
Stochastic Gradient Descent	70.4
Linear Discriminant Analysis	93.8
K-Nearest Neighbors	95.2
Decision Tree	94.6

Die Ergebnisse verdeutlichen, dass insbesondere die Modelle Logistic Regression, k-NN und Decision Tree ein hohes Potenzial für die Detektion von Anomalien in zyklischen Druckluftverbrauchsdaten aufweisen. Diese Modelle können aufgrund ihrer Interpretierbarkeit und Stabilität bevorzugt für die Integration in ein produktionsnahes Überwachungssystem eingesetzt werden. Gleichzeitig bestätigt die hohe Genauigkeit der

linearen Modelle (LR, LDA), dass die extrahierten Merkmale eine annähernd lineare Trennbarkeit der Klassen erlauben. Somit bilden diese Modelle eine robuste Grundlage für die anschließende Erweiterung der Analyse durch unüberwachte Lernverfahren.

Im dritten Ansatz der Modellierungsphase werden unüberwachte Lernverfahren (*unsupervised clustering*) eingesetzt, um Anomalien in den Druckluftverbrauchsdaten ohne vorliegende Label-Informationen zu identifizieren [vgl. ebd., S.50-51]. Im Gegensatz zu überwachten Methoden, die auf gelabelte Trainingsdaten angewiesen sind, versuchen unüberwachte Clustering-Algorithmen, Strukturen und Muster direkt aus den Daten heraus zu erkennen. Ziel ist es, Zyklen mit ähnlichen Merkmalsausprägungen zu Gruppen (*Cluster*) zusammenzufassen und solche Zyklen zu isolieren, die sich signifikant von der Mehrzahl unterscheiden. Die erheblich abweichenden Zyklen werden als potenzielle Anomalien interpretiert.

Für die vorliegende Untersuchung wurden die bereits in **Abbildung 53** gezeigte Merkmale herangezogen. Dabei erfolgte eine z-Standardisierung der Merkmalsvektoren, um eine gleichgewichtige Berücksichtigung aller Größenordnungen zu gewährleisten. Zur Identifikation von Anomalien wurde der k-Means-Algorithmus eingesetzt, der zu den meistverwendeten Clustering-Verfahren gehört und auf dem Prinzip der Minimierung intra-clusterlicher Distanzen basiert (vgl. **Kapitel 3.3.3**). Der Algorithmus teilt die Daten in k Cluster, sodass die Summe der quadrierten Abstände der Datenpunkte zu ihren jeweiligen Clusterzentren minimal ist. Im Kontext der Druckluftdaten entspricht ein Cluster einem typischen Verbrauchsmuster pro Werkzeug, während Punkte mit großer Distanz zum Clusterzentrum als potenzielle Anomalien interpretiert werden. Die Evaluierung des Algorithmus erfolgte auf Basis des zuvor gelabelten Testdatensatzes, um die Güte der automatischen Gruppierung zu bewerten. Die resultierende Zuordnung ist in der in **Abbildung 55** dargestellten Konfusionsmatrix zusammengefasst [vgl. ebd., S.51]. Von insgesamt 901 betrachteten Zyklen wurden 661 von 664 als *normal* korrekt zugeordnet, während 134 von 237 als *anomal* richtig erkannt wurden. Zusammenfassend resultieren folgende Werte:

- **Wahre Negative (TN)**: 661 normal korrekt klassifiziert,
- **Falsch Positive (FP)**: 3 normal fälschlich als anomal erkannt,
- **Falsch Negative (FN)**: 103 Anomalien nicht erkannt,
- **Wahre Positive (TP)**: 134 Anomalien korrekt erkannt.

Aus diesen Werten ergibt sich eine Genauigkeit (*Accuracy*) von

$$\text{Accuracy} = \frac{TP + TN}{N} = \frac{134 + 661}{901} \approx 88.24\%.$$

Der Anteil falsch positiver Klassifikationen an allen untersuchten Zyklen beträgt lediglich 0,33 %. Diese sehr niedrige Pseudo-Fehlerrate stellt einen Vorteil dar, da fälschlich als Anomalien klassifizierte Zyklen in der Praxis ein Risiko für unnötige Stillstände darstellen könnten. k-Means neigt hier zu einer konservativen Bewertung und kennzeichnet nur solche Zyklen als abweichend, die sich deutlich von der Mehrzahl unterscheiden. Allerdings zeigt

sich auch eine Schwäche des Algorithmus in den 103 nicht erkannten Anomalien (*False Negatives*). Diese deuten darauf hin, dass subtile, aber physikalisch relevante Veränderungen im Druckluftverbrauch vom Modell nicht zuverlässig erfasst werden. Da k-Means auf der Annahme gleichförmiger, konvexer Cluster basiert, können komplexe oder überlappende Verbrauchsmuster, wie sie bei unterschiedlichen Werkzeugkonfigurationen auftreten, nur eingeschränkt abgebildet werden. Dies kann dazu führen, dass bestimmte Anomalien, etwa durch schleichende Leckagen oder inkonsistente Taktverläufe, nicht als solche erkannt werden. Trotz dieser Einschränkungen bietet der k-Means-Algorithmus aufgrund seiner Interpretierbarkeit, geringen Rechenkomplexität und der hohen Klassifikationsgüte eine solide Grundlage für die Anomalieerkennung im Rahmen der Druckluftverbrauchsanalyse. Seine Stärke liegt insbesondere in der Erkennung klar abgegrenzter Verbrauchsabweichungen, wie sie durch deutliche Prozessänderungen oder Fehlfunktionen der Ejektoren hervorgerufen werden.

Tatsächlicher Wert []	0	661	3
	1	103	134
		0	1
		Errechneter Wert []	

Abbildung 55: Konfusionsmatrix k-Means

(4)Bereitstellung. Im Gegensatz zu einer klassischen Modellbereitstellung im Sinne einer rein technischen Inferenz oder Ausführung von Algorithmen in einer Cloud- oder Dashboardumgebung steht in der vorliegenden Arbeit nicht die unmittelbare operative Nutzung einzelner Modelle im Vordergrund, sondern die Frage, welche der entwickelten datenanalytischen Ansätze sich unter den gegebenen Rahmenbedingungen der betrachteten Produktionsdomäne grundsätzlich einsetzen lassen und welche technischen, organisatorischen und methodischen Voraussetzungen hierfür erfüllt sein müssen. Die Bereitstellung der Analyseergebnisse ist daher weniger als unmittelbare Systemintegration zu verstehen, sondern vielmehr als domänenspezifische Überführung der gewonnenen Erkenntnisse in eine fundierte Entscheidungsgrundlage für eine zukünftige industrielle Implementierung.

Die durchgeführten Analysen zeigen, dass die Druckluftverbrauchsdaten der betrachteten Umformanlage eine hohe zeitliche Dynamik aufweisen und in starkem Maße von werkzeugspezifischen sowie prozessabhängigen Parametern beeinflusst werden. Diese Eigenschaften führen dazu, dass klassische Schwellenwertverfahren oder rein statistische Ansätze nur eingeschränkt geeignet sind, um Abweichungen oder Anomalien zuverlässig zu

identifizieren. Verfahren, die zyklische Muster sowie mehrdimensionale Zusammenhänge zwischen Merkmalen explizit berücksichtigen, erweisen sich hingegen als deutlich robuster. Insbesondere Ansätze auf Basis der MMD sowie überwachte und unüberwachte Lernverfahren sind in der Lage, wiederkehrende Verbrauchscharakteristika und strukturelle Veränderungen im Zeitverlauf konsistent abzubilden. Gleichzeitig wurde deutlich, dass die untersuchten Verfahren jeweils unterschiedliche Anforderungen und Einschränkungen mit sich bringen. Während die MMD eine sehr präzise Erkennung von Formveränderungen in den Verbrauchsverläufen erlaubt, ist ihr Einsatz aufgrund der erforderlichen paarweisen Distanzberechnungen zwischen vollständigen Zyklen in der aktuellen Ausprägung nur bedingt für eine echtzeitnahe Anwendung geeignet. Überwachte Lernverfahren zeigen zwar eine hohe Klassifikationsgüte, setzen jedoch die Verfügbarkeit gelabelter Trainingsdaten voraus, die im industriellen Umfeld typischerweise nur begrenzt und unvollständig vorliegen. Unüberwachte Verfahren ermöglichen demgegenüber eine autonome Strukturerkennung ohne explizite Zielvariable, reagieren jedoch sensibel auf veränderte Prozessparameter und erfordern daher eine kontinuierliche Nachkalibrierung, um langfristig stabile Ergebnisse zu liefern. Aus diesen Beobachtungen lassen sich zentrale Voraussetzungen für eine domänenspezifische Integration datenanalytischer Modelle in der industriellen Praxis ableiten. Eine grundlegende Anforderung besteht in einer stabilen und echtzeitfähigen Datenanbindung an die Steuerungs- und Automatisierungsebene, sodass kontinuierliche Sensordatenströme ohne manuelle Extraktions- oder Nachbearbeitungsschritte für die Analyse verfügbar sind. Darüber hinaus müssen die eingesetzten Modelle hinsichtlich ihrer Rechen- und Speicheranforderungen für den Betrieb auf Edge-Geräten optimiert werden, da insbesondere distanzbasierte oder clusteringbasierte Verfahren in ihrer ursprünglichen Form eine hohe CPU-Last verursachen können. Ebenso ist eine weitgehend automatisierte Datenvorverarbeitung erforderlich, die Schritte wie Glättung, Segmentierung und Merkmalsextraktion umfasst und eine durchgängige Pipeline ohne Benutzereingriffe ermöglicht. Schließlich ist eine prozessnahe Einbettung der Modellergebnisse notwendig, sodass erkannte Abweichungen oder Anomalien unmittelbar in bestehende Instandhaltungs- und Entscheidungsprozesse rückgekoppelt werden können.

Vor diesem Hintergrund erfolgt die Bereitstellung der Ergebnisse für die betrachtete Produktionsdomäne in Form konkreter Handlungsempfehlungen für Produktions- und IT-Verantwortliche. Für eine industrielle Umsetzung erscheint insbesondere ein hybrider Ansatz geeignet, bei dem einfache statistische Vorfilter zur Reduktion von Störeinflüssen eingesetzt werden, bevor ressourcenschonende unüberwachte Lernverfahren auf der Edge-Ebene ausgeführt werden. Komplexere Analyseverfahren, wie etwa MMD-basierte Ansätze oder hochdimensionale Klassifikationsmodelle, sollten hingegen auf einer übergeordneten Server- oder Cloud-Ebene eingesetzt werden, um größere Datenmengen retrospektiv auszuwerten und Modelle regelmäßig zu aktualisieren. Zur schrittweisen Erweiterung der Datengrundlage wird zudem empfohlen, auffällige Betriebszyklen systematisch durch das Instandhaltungspersonal zu kennzeichnen, um über die Zeit ein belastbares Labelset aufzubauen, das eine spätere Nachtrainierung überwacht lernender Verfahren ermöglicht.

Dennoch kann eine erste analytische Nutzung der Ergebnisse an das Presswerk übergeben werden, um daraus domänenspezifisch verwertbare Informationen für die Instand-

haltung abzuleiten. Während die bisherige Betrachtung auf die Erkennung einzelner Anomalien fokussiert war, liegt insbesondere für eine prädiktive Nutzung der Modelle der entscheidende Mehrwert in der zeitlichen Aggregation der identifizierten Auffälligkeiten. Hierzu wurde die Häufigkeit der als anomal klassifizierten Zyklen über die gesamte Beobachtungsperiode ausgewertet. Die **Abbildung 56** zeigt exemplarisch die auf Basis des k-Means-Modells identifizierten Anomalien über den Verlauf von rund 26.000 Pressenzyklen [vgl. Jericho 2022, S.51]. Für die Auswertung wurde ein gleitendes Fenster von 5.000 Zyklen gewählt, um die Entwicklung der Anomalienrate über die Zeit zu analysieren. Der hellgrüne Bereich markiert den jeweils betrachteten Zeitraum.

Eine manuelle Validierung der Ergebnisse anhand der Anlagen- und Werkstattbücher bestätigt diese Beobachtung. Demnach kam es bei Hub 21.823 zu einem dokumentierten **Stillstand an Transfer 1**, bei dem ein fehlerhafter Sauger ausgetauscht wurde. Dieser Eingriff ist zeitlich exakt mit dem im Diagramm erkennbaren Wendepunkt der Anomalienhäufigkeit korreliert. Nach der Durchführung der Maßnahme nahm die Anzahl der erkannten Anomalien signifikant ab, was auf die erfolgreiche Behebung der zugrunde liegenden Störung hinweist. Damit konnte erstmals ein direkter Zusammenhang zwischen einer datenbasiert detektierten Anomalienhäufung und einem realen Instandhaltungseignis nachgewiesen werden. Diese Beobachtung unterstreicht den praktischen Nutzen des datengetriebenen Ansatzes. Die Häufung von Anomalien kann als Frühindikator für den Verschleiß oder das Versagen einzelner Komponenten interpretiert werden. Der Rückgang der Anomalien nach einer gezielten Wartungsmaßnahme belegt zugleich, dass das entwickelte Verfahren in der Lage ist, tatsächliche physikalische Veränderungen im Druckluftsystem abzubilden und deren Behebung im Datenverlauf sichtbar zu machen.




Abbildung 56: Anzahl der mit k-Means erkannten Anomalien über die Anzahl Hübe

Die gleiche Analyse wurde mit dem MMD-Ansatz durchgeführt (vgl. **Abbildung 57**; [vgl. ebd., S.52]). Hier zeigt sich ein ähnlicher Verlauf, jedoch mit einer höheren Gesamtzahl erkannter Anomalien. Dies ist darauf zurückzuführen, dass der gewählte Schwellenwert der MMD (τ_{MMD}) relativ niedrig angesetzt wurde, wodurch auch geringfügige Formabweichungen der Verbrauchsverläufe bereits als Anomalien klassifiziert werden. Der MMD-Ansatz reagiert damit sensibler auf subtile Veränderungen, was für die Frühwarnung von Vorteil sein kann, gleichzeitig jedoch das Risiko von Fehlalarmen erhöht.




Abbildung 57: Anzahl der mit MMD erkannten Anomalien über die Anzahl Hübe

Aus analytischer Sicht ergibt sich hieraus ein klarer Handlungsvorschlag. Anstatt ausschließlich Einzelanomalien zu betrachten, sollte die Anomalienfrequenz als zeitabhängige Zustandsgröße interpretiert werden. Durch die Aggregation über festgelegte Zeit- oder Zyklusfenster entsteht ein Verlaufssignal, das Rückschlüsse auf den Systemzustand ermöglicht. Steigt die Häufigkeit der Anomalien über mehrere Fenster hinweg kontinuierlich an, deutet dies auf eine fortschreitende Abnutzung des Systems hin. Sobald dieser Verlauf eine definierte Schwellkurve überschreitet, kann daraus ein prädiktiver Wartungsindikator abgeleitet werden.

Für eine zukünftige Implementierung im industriellen Umfeld wird daher empfohlen, die berechneten Anomalienwerte kontinuierlich in der Industrial Edge-Umgebung zu installieren und die Ergebnisse der Algorithmen über die Überwachungssysteme zu visualisieren. Auf diese Weise lässt sich aus den datengetriebenen Modellansätzen ein unmittelbar nutzbarer Mehrwert für zunächst die prädiktive Instandhaltung der Druckluftsysteme generieren. Eine spätere Erweiterung bei Vorhandensein der automatisierten Bereitstellung von Domänenwissen kann die Logik erweitert und die Modellierung um überwachte Lernmethoden ergänzt werden mit der anschließenden Ableitung der Handlungsempfehlung im Sinne der präskriptiven Instandhaltungsstrategie.

Die Fallstudie zum Druckluftgreifer verdeutlicht exemplarisch, wie datengetriebene Analyseverfahren zur Bewertung und Überwachung pneumatischer Subsysteme in der Umformtechnik eingesetzt werden können. Die Kombination aus statistischen, modellbasierten und lernenden Verfahren hat gezeigt, dass sich trotz der hohen Prozessdynamik und der werkzeugspezifischen Parametervariabilität charakteristische Verbrauchsmuster ableiten lassen, die eine differenzierte Einschätzung des Systemzustands ermöglichen. Während einfache Schwellenwertmethoden den komplexen Zusammenhängen im Druckluftsystem nicht gerecht werden, konnten die modellbasierten Ansätze (MMD, k-Means, überwachte Klassifikatoren) signifikante Anomalien mit hoher Zuverlässigkeit identifizieren. Gleichzeitig wurde deutlich, dass keine Methode allein alle Anforderungen einer industriellen Echtzeitanwendung erfüllt. Die Kombination aus leichteren, auf der Edge-Ebene lauffähigen Verfahren und komplexeren, cloudbasierten Modellen zur nachgelagerten Analyse stellt

daher einen vielversprechenden Ansatz für die zukünftige Praxis dar. Durch die analytische Aggregation der Anomalien über die Zeit konnte zudem gezeigt werden, dass datengetriebene Modelle nicht nur der reinen Fehlererkennung dienen, sondern als prädiktive Werkzeuge zur Zustandsüberwachung und Wartungsplanung eingesetzt werden können.

6.4.4 Gesamtauswertung und Fazit der Data-Mining-Anwendungen

Die dargestellten Fallstudien zum Ziehkissen, zum Zahnstangenantrieb und zum Druckluftgreifer dienen der Demonstration der im Rahmen dieser Arbeit entwickelten Data-Mining-Methodik sowie der zugrunde liegenden intelligenten Data Pipeline. Methodisch sind sie im Kontext des DSR als Demonstrationsphase der Artefaktentwicklung zu verstehen und folgen zugleich der Logik des Fallstudiendesigns (vgl. **Kapitel 2.3, 2.5.2**). Ziel dieser Phase ist es, die Funktionsfähigkeit, Anwendbarkeit und Anschlussfähigkeit der entworfenen Lösung in realen industriellen Szenarien nachzuweisen. Die anschließende Evaluation der Artefakte erfolgt in **Kapitel 7** durch Experteninterviews, welche die gewonnenen Ergebnisse reflektieren und bewerten.

Die Ziehkissen-Fallstudie stellt die erste Anwendung und zugleich den methodischen Ausgangspunkt dar. Sie verfolgte das Ziel, die Funktionsfähigkeit der intelligenten Data Pipeline im produktionsnahen Einsatz nachzuweisen. Durch die Integration realer Maschinendaten, deren Aufbereitung, Feature-Extraktion und modellbasierte Klassifikation konnte die technische Durchgängigkeit des Systems von der Datenerfassung bis zur analytischen Auswertung erfolgreich demonstriert werden. Im Rahmen dieser Fallstudie wurde gezeigt, dass die entwickelte Pipeline in der Lage ist, Daten automatisiert, konsistent und in Echtzeit über alle Verarbeitungsstufen hinweg zu verarbeiten. Gleichzeitig konnte mit Hilfe überwachter Lernverfahren eine zuverlässige Klassifikation von Prozesszuständen erreicht werden. Die Ergebnisse belegten, dass datengetriebene Verfahren, eingebettet in eine konsistente Dateninfrastruktur, physikalisch determinierte Abnutzungsprozesse valide abbilden und als Grundlage für kausal-prädiktive Zustandsbewertungen dienen können. Die Fallstudie diente damit der technischen und methodischen Demonstration des Artefakts und übernahm im DSR-Zyklus die Rolle der Demonstrationsphase. Zugleich entspricht sie einer theoretischen Replikation, da sie die in der Konzeptionsphase formulierten Annahmen unter realen Bedingungen überprüfte und bestätigte. Eine wesentliche Herausforderung bestand in der organisatorischen Einbindung der analytischen Ergebnisse. Zwar konnten Anomalien zuverlässig detektiert werden, deren Integration in operative Instandhaltungsprozesse erfolgte jedoch noch nicht vollständig automatisiert, was die Notwendigkeit einer engeren Verzahnung technischer und organisatorischer Ebenen verdeutlichte.

Die Fallstudie zum Zahnstangenantrieb stellte eine methodische Weiterentwicklung dar und fokussierte die Demonstration datenbasierter Modelle in einem dynamisch geregelten System. Ziel war es, auf Basis von Reglerparametern und Prozesssignalen Zusammenhänge zwischen Regelabweichungen und mechanischem Verschleiß zu identifizieren. Hierzu wurde ein Transfer-Simulator eingesetzt, der den Abgleich von simulierten und realen Prozesszuständen erlaubte und damit eine kontrollierte Untersuchung der Modellgüte ermöglichte. Im Gegensatz zur Ziehkissen-Analyse lag der Schwerpunkt dieser Fallstudie weniger auf der infrastrukturellen Validierung als vielmehr auf der modelltheoretischen Übertragbarkeit und

der Bewertung der Robustheit der entwickelten Methodik. Im Sinne des Fallstudiendesigns kann sie als analytische Replikation interpretiert werden, da sie die Grundprinzipien der Methodik auf ein komplexeres, nichtlineares und regelungstechnisch überlagertes System übertrug. Die Ergebnisse verdeutlichten, dass datengetriebene Verfahren auch in geregelten Systemen zur Identifikation von Verschleißmustern geeignet sind, sofern Regelabweichungen und physikalische Einflussgrößen systematisch verknüpft werden. Zugleich zeigte sich, dass die begrenzte Verfügbarkeit realer Verschleißdaten und die Dominanz simulationsbasierter Szenarien die Aussagekraft der Modelle einschränkten. Dennoch belegte die Studie, dass die intelligente Data Pipeline als technische Integrationsplattform auch externe, modellbasierte Ansätze aufnehmen und konsistent in den Analyseprozess einbetten kann. Damit leistete die Zahnstangenantrieb-Fallstudie einen entscheidenden Beitrag zur methodischen und technischen Übertragbarkeit der entwickelten Lösung.

Die Untersuchung der Druckluftgreifer bildete den explorativen Abschluss der Data-Mining-Anwendungen. Sie verfolgte die Zielsetzung, Lernverfahren in datenunsicheren, stark variierenden Produktionsumgebungen zu erproben. Aufgrund heterogener Prozesszustände wurde der Fokus auf die Erkennung von Mustern und Anomalien in Signalen gelegt, die den Luftverbrauch aufnehmen. Die Analyse zeigte, dass auch ohne explizite Zielgrößen charakteristische Abweichungen identifiziert und plausibel mit beobachteten Störungen korreliert werden konnten. Diese Ergebnisse unterstreichen das Potenzial unüberwachter Lernmethoden für Frühindikationssysteme, insbesondere in Anwendungsfällen, in denen eine vollständige Prozessannotierung nicht realisierbar ist. Methodisch entspricht diese Fallstudie einer explikativen Replikation, da sie die Methodik auf ein stark verändertes Anwendungsszenario überträgt und deren Grenzen sowie Adaptivität überprüft. Im DSR-Kontext erfüllte sie die Rolle einer reflektierenden Demonstration, die die Generalisierbarkeit und Skalierbarkeit des Artefakts unter Praxisbedingungen aufzeigte. Die größte Herausforderung lag hier in der Signalqualität und Synchronisation der Sensordaten, wodurch deutlich wurde, dass die Leistungsfähigkeit datengetriebener Ansätze maßgeblich von der Qualität und Kohärenz der Eingangsdaten abhängt.

Im Kontext dieser Arbeit wird Wissen nicht als isolierte Sammlung von Analyseergebnissen verstanden, sondern als strukturierte Verknüpfung aus Daten, modellbasierten Bewertungen und domänenspezifischem Kontext. Wissen entsteht demnach dort, wo sensorische Beobachtungen, analytische Muster und technische Erfahrungswerte gemeinsam interpretiert werden und dadurch eine belastbare Einordnung des Systemzustands ermöglichen. Die Fallstudien zeigen, dass datenanalytische Modelle insbesondere dann Mehrwert erzeugen, wenn ihre Ergebnisse in bestehende Wissensbestände eingebettet und im Lichte bekannter Prozesszusammenhänge bewertet werden. Die intelligente Data Pipeline fungiert hierbei als technische und methodische Infrastruktur zur Wissensentstehung, nicht als eigenständiges Entscheidungssystem.

Im Vergleich verdeutlichen die drei Fallstudien eine zunehmende methodische und kontextuelle Komplexität und zugleich eine stringente forschungslogische Abfolge. Während die Ziehkissen-Analyse primär die technische Funktionsfähigkeit der intelligenten Data Pipeline nachwies und damit die Mikroebene des Artefakts validierte, fokussierte die Zahnstangenantrieb-Studie auf die methodische Generalisierung und modelltheoretische

Robustheit. Die Druckluftgreifer-Studie schließlich erweiterte die Untersuchung auf datenunsichere und heterogene Produktionsbedingungen und lieferte damit Erkenntnisse zur Skalierbarkeit und Anpassungsfähigkeit der entwickelten Methodik. Zusammengefasst bilden die Fallstudien ein konsistentes Demonstrationsdesign im Sinne einer eingebetteten Multifallstudie, das sowohl theoretische als auch analytische Replikationen umfasst und dadurch den Nachweis der Funktionsfähigkeit und Anwendbarkeit des entwickelten Artefakts unter unterschiedlichen Rahmenbedingungen ermöglicht.

Über alle drei Fallstudien hinweg zeigt sich, dass die entwickelten Ansätze insbesondere dort ihre Stärke entfalten, wo datengetriebene Modelle nicht isoliert statistische Korrelationen abbilden, sondern in Kombination mit domänenspezifischem Prozessverständnis interpretiert werden. In diesem Sinne lassen sich die vorgestellten Verfahren als kausalprädiktive Ansätze einordnen, bei denen prognostische Aussagen stets im Kontext physikalischer Wirkzusammenhänge, regelungstechnischer Abhängigkeiten oder prozesslogischer Zyklen bewertet werden. Die Fallstudien belegen damit, dass die intelligente Data Pipeline nicht lediglich prädiktive Modelle bereitstellt, sondern eine strukturierte Grundlage schafft, um Ursache-Wirkungs-Beziehungen datenbasiert zu untersuchen und für zustandsorientierte Bewertungen nutzbar zu machen. Die empirischen Erkenntnisse zeigen, dass die entworfene Methodik grundsätzlich geeignet ist, komplexe Produktionssysteme datengetrieben zu analysieren und Verschleißphänomene zuverlässig zu identifizieren. Gleichzeitig werden zentrale Handlungsfelder sichtbar, die weniger als isolierte technische Defizite, sondern vielmehr als systemische Eigenschaften datengetriebener Ansätze im industriellen Umfeld zu interpretieren sind. Zwar konnte eine technische Datendurchgängigkeit über alle Ebenen hinweg realisiert werden, deren wirksame Nutzung setzt jedoch eine weitergehende semantische Standardisierung sowie eine stärkere organisatorische Einbettung der Analyseergebnisse in betriebliche Entscheidungsprozesse voraus. Die Akzeptanz der Modelle hängt dabei wesentlich von ihrer Interpretierbarkeit und Transparenz ab, weshalb erklär- und nachvollziehbare Verfahren und nachvollziehbare Modelllogiken eine zentrale Rolle spielen. Darüber hinaus erweist sich die Qualität, Konsistenz und Annotation der Daten als grundlegende Voraussetzung für belastbare Analyseergebnisse, insbesondere im Hinblick auf überwachtetes Lernen. Schließlich zeigt sich, dass die Skalierbarkeit der Methodik über unterschiedliche Anwendungsdomänen hinweg nur dann gewährleistet ist, wenn eine flexible und sicherheitskonforme Einbindung in hybride Edge- und Cloud-Architekturen möglich ist. Diese Spannungsfelder markieren keine Schwächen des Referenzmodells, sondern verdeutlichen die realen Rahmenbedingungen, unter denen datengetriebene Instandhaltungsansätze nachhaltig etabliert und weiterentwickelt werden müssen.

Die in den Fallstudien erzielten Ergebnisse sind dabei nicht als vollständige Umsetzung präskriptiver Entscheidungslogiken zu verstehen, sondern als gezielte Vorbereitung einer solchen Weiterentwicklung. Die Arbeit zeigt, dass durch die Kombination prädiktiver Modelle mit domänenspezifischem Kontextwissen ein Entscheidungsraum entsteht, in dem nicht nur Zustände vorhergesagt, sondern auch potenzielle Handlungsoptionen systematisch vorbereitet werden können. Die Ableitung konkreter Maßnahmen verbleibt bewusst außerhalb des Analyseprozesses und ist an organisatorische, sicherheitsrelevante und haftungsbezogene Rahmenbedingungen gebunden. Gleichwohl schaffen die entwickel-

ten kausal-prädiktiven Ansätze die notwendige Grundlage, um in zukünftigen Ausbaustufen präskriptive Instandhaltungsstrategien methodisch fundiert zu unterstützen. Insgesamt belegen die Data-Mining-Anwendungen die technische Wirksamkeit und methodische Anschlussfähigkeit der intelligenten Data Pipeline. Sie verdeutlichen, dass der DSR-Ansatz in Verbindung mit der Fallstudienmethodik ein geeignetes Forschungsgerüst darstellt, um sowohl die technische Umsetzung als auch die wissenschaftliche Fundierung datengetriebener Ansätze in der industriellen Produktion zu gewährleisten. Durch die sequenzielle Durchführung und die analytische Replikation der Fallstudien wurde eine belastbare Generalisierung erreicht, die zeigt, dass datenbasierte Zustandsanalysen nicht nur unter kontrollierten Bedingungen, sondern auch in komplexen, heterogenen Produktionsumgebungen anwendbar sind. Die Ergebnisse liefern damit sowohl empirische Evidenz als auch praxisrelevante Handlungsempfehlungen für die Integration intelligenter, datengetriebener Systeme in industrielle Wertschöpfungsprozesse.

6.5 Systematischer Anforderungsabgleich

Ziel dieses Abschnitts ist der systematische Abgleich der in **Kapitel 5.9** abgeleiteten Anforderungen an das Referenzmodell einer intelligenten Data Pipeline mit den im Rahmen der Integration in die reale Produktionsumgebung (**Kapitel 6.3**) sowie der datenanalytischen Anwendungsfälle (**Kapitel 6.4**) erzielten Ergebnissen. Der Anforderungsabgleich dient dazu, den erreichten Umsetzungsstand des entwickelten Artefakts transparent und nachvollziehbar einzuordnen und dessen konzeptionelle sowie technische Anschlussfähigkeit an den industriellen Anwendungskontext zu bewerten.

Im Fokus steht dabei nicht eine normative Bewertung im Sinne einer Nutzen- oder Wirtschaftlichkeitsanalyse, sondern die strukturierte Gegenüberstellung von konzeptionell formulierten Soll-Anforderungen und praktisch realisierten Ist-Ausprägungen des Referenzmodells. Der Abgleich folgt damit der Logik des DSR, nach der Artefakte schrittweise entwickelt, demonstriert und reflektiert werden, ohne dass bereits in dieser Phase eine abschließende Evaluation der Praxistauglichkeit vorgenommen wird. Entsprechend konzentriert sich dieser Abschnitt auf die Frage, in welchem Umfang die einzelnen Anforderungen im Rahmen der prototypischen Umsetzung vollständig erfüllt, teilweise adressiert oder lediglich vorbereitend angelegt werden konnten.

Der systematische Anforderungsabgleich erfüllt dabei eine doppelte Funktion. Zum einen schafft er Transparenz über die Leistungsfähigkeit und Reife des entwickelten Referenzmodells im betrachteten Brownfield-Kontext und macht explizit, welche Aspekte technisch realisiert werden konnten und wo infrastrukturelle, organisatorische oder domänenspezifische Restriktionen wirksam wurden. Zum anderen bildet er die methodische Brücke zwischen der artefaktorientierten Gestaltungs- und Demonstrationsphase dieser Arbeit und der nachfolgenden Evaluation in **Kapitel 7**. Die dort durchgeführten Experteninterviews knüpfen gezielt an die hier dokumentierten Erfüllungsgrade an und ermöglichen eine reflexive Bewertung der praktischen Relevanz, der Umsetzbarkeit sowie des wahrgenommenen Nutzens des Referenzmodells aus Sicht der Domänenexperten.

Der Abgleich der Anforderungen erfolgt auf Basis der in **Kapitel 5.9** konsolidierten Anforderungsmatrix und berücksichtigt ausschließlich jene Anforderungen, die aus der

konzeptionellen Entwicklung des Referenzmodells hervorgegangen sind. Erfahrungsbasierte oder kontextabhängige Zusatzanforderungen, die sich erst im Zuge der praktischen Anwendung ergeben haben, werden bewusst nicht in diesen Abschnitt integriert, sondern im Rahmen der Evaluation gesondert reflektiert. Auf diese Weise wird eine klare methodische Trennung zwischen konzeptioneller Ableitung, technischer Demonstration und empirischer Bewertung gewährleistet.

Zur Einordnung des Umsetzungsstands wird eine dreistufige Bewertungslogik verwendet. *Erfüllt* bezeichnet Anforderungen, die im Rahmen der implementierten intelligenten Data Pipeline vollständig adressiert und funktionsfähig umgesetzt wurden. *Teilweise erfüllt* kennzeichnet Anforderungen, deren zentrale Aspekte realisiert sind, deren vollständige Umsetzung jedoch durch technische, organisatorische oder infrastrukturelle Rahmenbedingungen eingeschränkt war. *Vorbereitet* beschreibt Anforderungen, für die konzeptionelle und strukturelle Voraussetzungen geschaffen wurden, deren operative Nutzung oder vollständige Integration jedoch noch nicht Bestandteil der Demonstration war. Diese Differenzierung ermöglicht eine präzise Abgrenzung zwischen konzeptioneller Zielsetzung und praktisch erreichbarem Umsetzungsstand, ohne die Ergebnisse der späteren Evaluation vorwegzunehmen. Der sich ergebende Anforderungsabgleich ist in der **Tabelle 14** dargestellt.

Der systematische Abgleich der in **Kapitel 5.9** abgeleiteten Anforderungen mit dem im Rahmen der Demonstrationsphase realisierten Umsetzungsstand zeigt ein insgesamt konsistentes und erwartbares Erfüllungsbild. Die Mehrheit der Anforderungen wird entweder vollständig erfüllt oder zumindest teilweise erfüllt, was die grundsätzliche Funktionsfähigkeit und Anschlussfähigkeit des entwickelten Referenzmodells im industriellen Anwendungskontext bestätigt. Die vollständig erfüllten Anforderungen konzentrieren sich vor allem auf die technisch-strukturellen Kernaspekte der intelligenten Data Pipeline. Dazu zählen insbesondere die Integration heterogener Datenquellen (R1), die einheitliche zeitliche Referenzierung (R3), die konsistente Informationsintegration (R4), die explizite Problemdefinition und Dokumentation von Zielmetriken (R6) sowie die funktionale Trennung zwischen Modellentwicklung und produktivem Betrieb (R8). Diese Ergebnisse belegen, dass die im Referenzmodell konzipierten Daten- und Analyseflüsse in der Praxis technisch realisierbar sind und eine durchgängige Verarbeitung von der Datenerfassung bis zur Analyse und Visualisierung ermöglichen.

Demgegenüber zeigen sich bei Anforderungen mit starkem Wissens-, Organisations- oder Governance-Bezug bewusst graduelle Erfüllungsgrade. Insbesondere die digitale Erfassung und Nutzung von Domänenwissen (R2), der Aufbau einer vollständig integrierten Wissensbasis (R5) sowie das versionierte Merkmalsmanagement (R7) wurden zwar konzeptionell und teilweise technisch adressiert, konnten jedoch im Rahmen der Demonstrationsphase noch nicht vollständig automatisiert umgesetzt werden. Diese Befunde sind weniger als Defizite des Referenzmodells zu interpretieren, sondern vielmehr als Folge realer organisatorischer, infrastruktureller und sicherheitsrelevanter Restriktionen einer industriellen Brownfield-Umgebung.

Die als *vorbereitet* bewerteten Anforderungen, wie die Adaptionen- und Retrainingfähigkeit der Modelle (R11) sowie die wissensbasierte Ableitung von Handlungsempfehlungen (R13), markieren bewusst den Übergang von kausal-prädiktiven zu präskriptiven Analyse-

Tabelle 14: Systematischer Abgleich der Anforderungen mit dem Umsetzungsstand

ID	Anforderung	Umsetzungs- stand	Begründung
R1	Integration heterogener Datenquellen	erfüllt	Strukturierte Sensordaten sowie unstrukturierte Dokumente wurden erfolgreich integriert.
R2	Digitale Erfassung von Domänenwissen	teilweise erfüllt	Domänenwissen ist digital verfügbar, jedoch noch nicht vollständig automatisiert angebunden.
R3	Einheitliche zeitliche Referenzierung	erfüllt	Zeitstempelbasierte Synchronisation über alle relevanten Datenströme umgesetzt.
R4	Konsistente Informationsintegration	erfüllt	Zusammenführung maschineller Daten und Domänenwissen in einer gemeinsamen Integrationsschicht.
R5	Persistente Wissensbasis	teilweise erfüllt	Wissensspeicherung vorhanden, jedoch ohne vollständige Kopplung an das Überwachungssystem.
R6	Explizite Problemdefinition und Metriken	erfüllt	Problemstellungen und Zielgrößen sind je Fallstudie klar dokumentiert.
R7	Versionierbares Merkmalsmanagement	teilweise erfüllt	Feature Engineering umgesetzt, jedoch ohne dedizierten Feature Store.
R8	Trennung Training und Betrieb	erfüllt	Training in Cloud-Umgebung, Inferenz im Edge-Betrieb realisiert.
R9	Produktiver Modellbetrieb	erfüllt	Modelle werden im operativen Betrieb mit Echtzeitdaten versorgt.
R10	Modellüberwachung	teilweise erfüllt	Grundlegendes Monitoring vorhanden, Drift-Erkennung noch nicht automatisiert.
R11	Adaptions- und Retrainingfähigkeit	vorbereitet	Konzeptionell vorgesehen, jedoch noch nicht kontinuierlich implementiert.
R12	Ergebnisvisualisierung	erfüllt	Analyseergebnisse werden über Dashboards adressatengerecht visualisiert.
R13	Ableitung von Handlungsempfehlungen	vorbereitet	Empfehlungslogik konzeptionell angelegt, noch nicht vollständig integriert.
R14	Funktionale Trennung Wissensnutzung	teilweise erfüllt	Wissensgenerierung und Nutzung getrennt, jedoch noch nicht auf einer gemeinsamen Plattform.

ansätzen. Zwar sind die konzeptionellen und architektonischen Voraussetzungen hierfür im Referenzmodell angelegt und in Teilen technisch vorbereitet, ihre vollständige Realisierung erfordert jedoch eine weitergehende Integration von Erfahrungswissen, organisatorischen Entscheidungsprozessen sowie automatisierten Rückkopplungsmechanismen. Damit unterstreichen diese Anforderungen zugleich das Entwicklungspotenzial des Referenzmodells über die Demonstrationsphase hinaus.

Insgesamt verdeutlicht der Anforderungsabgleich, dass das entwickelte Referenzmodell seine zentrale Zielsetzung erfüllt. Es stellt einen tragfähigen, methodisch fundierten und technisch anschlussfähigen Rahmen für kausal-prädiktive Datenanalysen in industriellen Produktionsumgebungen dar. Gleichzeitig zeigt der abgestufte Erfüllungsgrad einzelner Anforderungen, dass präskriptive Entscheidungsunterstützung nicht als isolierte technische Funktion verstanden werden kann, sondern als evolutiver Reifegrad, der auf einer stabilen Daten-, Modell- und Wissensbasis aufbaut. Diese Erkenntnis bildet die inhaltliche Brücke zur nachfolgenden Evaluation in **Kapitel 7**, in der insbesondere die organisatorische, fachliche und praktische Bewertung des Referenzmodells in den Vordergrund rückt.

7 Evaluation

Im Rahmen des Forschungsansatzes dieser Arbeit stellt die Evaluation eine zentrale Phase dar, in der die Nützlichkeit, Anwendbarkeit und Praxistauglichkeit des Artefakts systematisch überprüft wird (vgl. **Kapitel 2.5.3**). Entsprechend gilt es, das in **Kapitel 5** konzipierte Referenzmodell einer intelligenten Data Pipeline sowie dessen in **Kapitel 6** dargestellte exemplarische Anwendung im industriellen Produktionsumfeld zu evaluieren.

Im Folgenden wird in **Kapitel 7.1** die Auswahl der Experten sowie die Herleitung des Interviewleitfadens dargestellt. Daran anschließend erfolgt in **Kapitel 7.2** die Auswertung der durchgeführten Experteninterviews. Abschließend wird in **Kapitel 7.3** der Anforderungsabgleich auf Basis der durchgeführten Evaluation dargelegt.

7.1 Expertenauswahl und Herleitung des Interviewleitfadens

Nach *Lamnek (2016)* erlaubt eine leitfadenorientierte Gesprächsführung die strukturierte Erfassung expertenbasierten Sonderwissens, ohne dabei die Offenheit für individuelle Sichtweisen und unerwartete thematische Erweiterungen einzuschränken (vgl. **Kapitel 2.5.3**). Der semistrukturierte Ansatz fördert dabei explizit die Offenheit des Gesprächsverlaufs, sodass im Verlauf des Interviews zusätzliche, nicht im Leitfaden vorab formulierte Fragen entstehen oder bislang nicht betrachtete, aber relevante Aspekte durch die Experten eingebracht werden können. Vor diesem methodischen Hintergrund dienen die Experteninterviews der anwendungsbezogenen Bewertung des im Rahmen des DSR-Projekts entwickelten Referenzmodells einer intelligenten Data Pipeline.

Im Mittelpunkt der Experteninterviews stehen die Einschätzung der Nützlichkeit, Anwendbarkeit, Praktikabilität sowie der Domänenübertragbarkeit des Referenzmodells und dessen Einordnung im Kontext datengetriebener, kausal-prädiktiver Instandhaltungsansätze. Darüber hinaus wird aus Expertensicht reflektiert, inwieweit die durch das Referenzmodell geschaffene Daten- und Analysebasis grundsätzlich geeignet ist, weiterführende präskriptive Entscheidungsprozesse zu unterstützen. Die Interviews dienen damit der reflektierten Einordnung des Artefakts aus der Perspektive der industriellen Praxis und ergänzen die zuvor dargestellte Demonstration im Anwendungskontext.

Die Auswahl der interviewten Experten erfolgte zielgerichtet entlang der Forschungs- und Evaluationsziele dieser Arbeit. Ziel war es, ein breites, zugleich aber thematisch fokussiertes Spektrum an Perspektiven aus dem industriellen Anwendungskontext abzudecken. Entsprechend wurden Experten ausgewählt, die über fundierte praktische Erfahrung in den Domänen Instandhaltung, Produktion, IT-Betrieb, IT-Architektur und Data Science verfügen und zugleich unterschiedliche Rollen, Entscheidungsebenen sowie Verantwortungsumfänge innerhalb industrieller Organisationen repräsentieren. Durch die bewusste Kombination operativer und strategischer Perspektiven sowie werk-, marken- und konzernbezogener Verantwortungsbereiche wird sichergestellt, dass sowohl die praktische Umsetzbarkeit als auch übergreifende Skalierungs- und Übertragbarkeitsaspekte des Referenzmodells reflektiert werden können. Darüber hinaus weisen die interviewten Experten eine hohe Erfahrungsbreite auf, die sich sowohl in langjähriger Berufserfahrung als auch in Tätigkeiten über mehrere Organisationseinheiten oder Unternehmen hinweg

manifestiert. Auf diese Weise wird eine fundierte, praxisnahe und zugleich differenzierte Bewertung des entwickelten Artefakts ermöglicht. Eine Übersicht der interviewten Experten sowie der zugrunde liegenden Auswahlkriterien ist in **Tabelle 15** dargestellt.

Vor dem Hintergrund dieser heterogenen, aber thematisch gezielt zusammengesetzten Expertenstichprobe wurde ein semistrukturierter Interviewleitfaden entwickelt, der eine vergleichbare Erhebung zentraler Themen- und Bewertungsbereiche ermöglicht und zugleich Raum für kontextspezifische Vertiefungen sowie individuelle Einschätzungen der Experten lässt. Die Konzeption und Durchführung der Experteninterviews basiert auf der in **Kapitel 2.5.3** beschriebenen methodischen Vorgehensweise. Inhaltlich orientiert sich der Interviewleitfaden an den in **Kapitel 4.2** abgeleiteten Forschungsfragen. Zur strukturierten Erfassung der relevanten Aspekte wird der Leitfaden in vier übergeordnete Themenbereiche gegliedert, deren Herleitung und inhaltliche Ausgestaltung im Folgenden dargestellt wird.

Zu Beginn des Interviews dient **Teil A** der Einordnung des Gesprächskontexts. Nach einer kurzen Einleitung und der Darstellung der Zielsetzung erfolgt ein Austausch zum beruflichen Hintergrund des interviewten Experten, um sowohl eine offene Gesprächsatmosphäre zu schaffen als auch die jeweilige Domänenexpertise einordnen zu können. Darauf aufbauend wird das Referenzmodell der intelligenten Data Pipeline sowie dessen Anwendung im industriellen Kontext visuell vorgestellt und mündlich erläutert. Die Darstellung der Artefakte ist während des gesamten Interviews bei Bedarf jederzeit abrufbar, sodass Rückfragen oder vertiefende Diskussionen unmittelbar aufgegriffen werden können.

Als Kernelement des Interviews fokussiert sich **Teil B** auf die strukturierte Bewertung des entwickelten Referenzmodells sowie der darauf aufbauenden Anwendungsfälle aus Sicht der interviewten Experten. Nach Szopinski et al. (2020) erfolgt die Auswahl geeigneter Evaluationskriterien im Kontext von DSR-Projekten in Abhängigkeit vom jeweiligen Betrachtungsgegenstand. Vor diesem Hintergrund werden für die vorliegende Untersuchung die Kriterien **Nützlichkeit**, **Verständlichkeit**, **Anwendbarkeit**, **Übertragbarkeit** und **Akzeptanz** herangezogen. Diese Kriterien bilden die Grundlage für eine systematische Erhebung der Experteneinschätzungen und unterstützen zugleich eine vergleichbare Auswertung der Interviewergebnisse. Die **Nützlichkeit** adressiert dabei, inwieweit das Referenzmodell reale Problemstellungen im Produktionsumfeld adressiert und einen erkennbaren praktischen Mehrwert erzeugt. Die **Verständlichkeit** prüft die strukturelle und inhaltliche Nachvollziehbarkeit des Referenzmodells sowie der dargestellten Anwendungsfälle. Die **Anwendbarkeit** beleuchtet die technischen, organisatorischen und ressourcenbezogenen Voraussetzungen für einen produktiven Einsatz des Referenzmodells und umfasst implizit Aspekte der Reproduzierbarkeit unter vergleichbaren Rahmenbedingungen. Die **Übertragbarkeit** fokussiert die Frage, inwieweit die konzeptionellen und architektonischen Prinzipien des Referenzmodells auf weitere Produktionskontexte ausgeweitet werden können, wobei insbesondere Skalierungsaspekte berücksichtigt werden. Ergänzend wird mit dem Kriterium der **Akzeptanz** eine soziotechnische Perspektive eingenommen, die untersucht, wie unterschiedliche Stakeholdergruppen das Referenzmodell wahrnehmen und welche Faktoren eine Einführung begünstigen oder behindern können.

Tabelle 15: Übersicht der interviewten Experten

ID	Rolle	Verantwortungsumfang	Entscheidungsebene	Domänenfokus	Erfahrung & Breite
E1	Fachexperte	Hauptwerk (Werk)	operativ	Instandhaltung, IT-Betrieb	10–15; mehrere Bereiche
E2	Fachexperte	Hauptwerk (Werk)	operativ	Instandhaltung	10–15; mehrere Bereiche
E3	Fachexperte	Hauptwerk (Werk)	operativ	Instandhaltung, IT-Betrieb	15+; mehrere Unternehmen
E4	Fachexperte	Hauptwerk (Bereich)	operativ	Instandhaltung	15+; mehrere Unternehmen
E5	Fachexperte	Hauptwerk (Bereich)	operativ	Instandhaltung	15+; mehrere Bereiche
E6	Führungskraft	Hauptwerk (Werk)	strategisch	Produktion	15+; mehrere Bereiche
E7	Führungskraft	Hauptwerk (Bereich)	strategisch	Instandhaltung	15+; mehrere Bereiche
E8	Führungskraft	Hauptwerk (Bereich)	strategisch	Produktion	10+; mehrere Bereiche
E9	Fachexperte	Hauptwerk (Werk)	operativ	Informatik, Data Science	10+; mehrere Bereiche
E10	Planer	Konzern	strategisch	Produktion, Instandhaltung	15+; mehrere Unternehmen
E11	Planer	Konzern	strategisch	Produktion	10+; mehrere Bereiche
E12	Führungskraft	Konzern	strategisch	IT-Betrieb	15+; mehrere Bereiche
E13	Fachexperte	Marke (international)	operativ	Instandhaltung	15+; mehrere Bereiche
E14	Planer	Marke (international)	operativ	Produktion	10+; mehrere Bereiche
E15	IT-Architekt	Konzern	strategisch	Produktion	15+; mehrere Unternehmen
E16	IT-Architekt	Konzern	strategisch	Produktion	10+; mehrere Bereiche
E17	Data Scientist	Konzern	strategisch	Data Science	10+; mehrere Bereiche
E18	Data Scientist	Marke (international)	operativ	Data Science	10+; mehrere Bereiche
E19	Führungskraft	Marke (international)	strategisch	Produktion	15+; mehrere Bereiche

Teil C des Interviewleitfadens dient der vertiefenden Exploration weiterführender praxisbezogener Einschätzungen der interviewten Experten. Im Fokus stehen dabei konkrete Erfahrungen, Herausforderungen und Einschätzungen aus dem industriellen Anwendungskontext, die über die strukturierte Bewertung hinausgehen. Insbesondere werden Aspekte adressiert, die im Rahmen der systematischen Literaturanalyse als Forschungsbedarf identifiziert wurden und im bisherigen Forschungsstand nur unzureichend abgedeckt sind. Dieser Interviewteil ist bewusst offen angelegt, um neue Perspektiven und bislang nicht betrachtete, aber relevante Themen erfassen zu können.

Zum Abschluss eröffnet **Teil D** einen bewusst offen gehaltenen Reflexionsraum, der den interviewten Experten die Möglichkeit gibt, über die zuvor behandelten Themen hinausgehende Anmerkungen, kritische Einschätzungen oder ergänzende Perspektiven einzubringen. Dieser Interviewteil dient dazu, Aspekte zu erfassen, die im Rahmen der strukturierten Bewertung nicht vollständig abgedeckt wurden, und ermöglicht zugleich eine abschließende Einordnung des Referenzmodells sowie der dargestellten Anwendungsfälle aus individueller Expertensicht.

Zur Sicherstellung einer vergleichbaren Erhebung zentraler Themenbereiche wurde ein semistrukturierter Interviewleitfaden verwendet. Die konkrete Ausgestaltung des Leitfadens in Form beispielhafter Leitfragen ist in **Tabelle 23** im **Anhang G** dargestellt. Die aufgeführten Fragestellungen dienten dabei als Orientierungshilfe für die Interviewführung und verdeutlichen die Operationalisierung der Evaluationskriterien, ohne den offenen Charakter der semistrukturierten Interviews einzuschränken.

7.2 Ergebnisauswertung der Experteninterviews

In diesem Kapitel werden die Ergebnisse der im Rahmen der Evaluation durchgeführten Experteninterviews systematisch ausgewertet und in Bezug auf das entwickelte Referenzmodell einer intelligenten Data Pipeline eingeordnet. Ziel der Auswertung ist es, die Einschätzungen der befragten Experten hinsichtlich der Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Akzeptanz des Artefakts strukturiert darzustellen und damit einen empirisch fundierten Beitrag zur Beantwortung der Forschungsfragen zu leisten.

Grundlage der Analyse bilden die vollständig transkribierten und inhaltlich-semantisch aufbereiteten Interviewdaten, die im Rahmen der semistrukturierten Gespräche erhoben wurden. Insgesamt wurden 19 Experteninterviews in die Auswertung einbezogen, die ein breites Spektrum an fachlichen Rollen, Verantwortungsbereichen und Erfahrungsniveaus abdecken (vgl. **Tabelle 15**). Die Interviews mit den Experten E15 und E16 fanden in einem gemeinsamen Gesprächstermin statt und wurden aufgrund des dialogischen Charakters als zusammengehörige Datenbasis ausgewertet. Die Ergebnisauswertung folgt einer thematisch strukturierten Vorgehensweise, die sich an den im Interviewleitfaden verankerten Evaluationsdimensionen orientiert. Diese Dimensionen dienen als analytischer Ordnungsrahmen, entlang dessen die Einschätzungen der Experten systematisch zusammengeführt und vergleichend betrachtet werden. Ziel ist es dabei nicht, einzelne Aussagen isoliert zu bewerten, sondern übergreifende Argumentationsmuster, wiederkehrende Einschätzungen sowie kontextabhängige Unterschiede herauszuarbeiten.

Im Zuge der qualitativen Auswertung zeigte sich, dass sich mit fortschreitender Interviewanzahl wiederkehrende Themen, Argumentationsmuster und Deutungslogiken in stabiler Weise herausbildeten. Ab dem sechzehnten Interview traten kaum neue inhaltliche Aspekte oder strukturell abweichende Perspektiven hinzu, sodass von einer theoretischen Sättigung im Sinne qualitativer Forschung ausgegangen werden kann (vgl. **Kapitel 2.5.3**). Die Sättigung bezog sich dabei nicht nur auf einzelne Aussagen, sondern auf die Kohärenz der Argumentationslogik innerhalb der fünf Evaluationsdimensionen. Auch bei emergenten Themenfeldern, etwa zur Rolle organisationaler Verantwortung oder zur Bedeutung erklärbarer Systeme, zeigte sich eine inhaltliche Stabilität der Einschätzungen. Vor diesem Hintergrund erscheint die Einbeziehung von neunzehn Experteninterviews in die Analyse methodisch angemessen und empirisch fundiert, da sie eine hinreichende thematische Tiefe sowie argumentative Breite gewährleistet.

Die Darstellung der Ergebnisse erfolgt in den nachfolgenden Unterkapiteln zunächst getrennt nach den fünf Evaluationsdimensionen. Abschließend werden die gewonnenen Erkenntnisse querschnittlich verdichtet, zentrale Muster und Spannungsfelder identifiziert und in Beziehung zueinander gesetzt. Auf diese Weise wird eine strukturierte und zugleich differenzierte Bewertung des entwickelten Referenzmodells aus Sicht der industriellen Praxis ermöglicht.

7.2.1 Nützlichkeit

Die befragten Experten bewerten das Referenzmodell der intelligenten Data Pipeline übereinstimmend als nützlich und praxisrelevant für den industriellen Instandhaltungskontext. Diese Einschätzung findet sich sowohl in den artefaktnahen Interviews der ersten Erhebungsphase (**E1–E9**) als auch in den späteren Gesprächen mit standortübergreifender beziehungsweise strategischer Perspektive (**E10–E19**). Aus Expertensicht liegt der zentrale Nutzen des Modells darin, bislang fragmentierte Aktivitäten der datengetriebenen Instandhaltung in einen konsistenten, nachvollziehbaren Ordnungsrahmen zu überführen und dadurch konkrete betriebliche Problemstellungen systematisch adressierbar zu machen (vgl. **E5-16; E8-16; E11-15; E19-14**).

Ein wiederkehrender Nutzenaspekt betrifft die frühzeitige Erkennung potenzieller Fehlerzustände mit dem Ziel, ungeplante Anlagenstillstände zu vermeiden. In den Interviews wird deutlich, dass reaktive Instandhaltungsstrategien im Produktionsalltag häufig zu kurzfristigen und kostenintensiven Unterbrechungen führen. Mehrere Experten verweisen darauf, dass sich viele Störungen nicht abrupt ereignen, sondern im Vorfeld durch veränderte Zustandsmuster ankündigen (vgl. **E3-20; E4-15**). Die im Referenzmodell vorgesehene Kombination aus kontinuierlicher Datenerfassung und datengetriebenen Analyseverfahren wird daher als zentraler Hebel zur Erhöhung der Anlagenverfügbarkeit eingeschätzt. Der in den Fallstudien gezeigte zeitliche Vorlauf wird von den Interviewten als besonders handlungsrelevant bewertet, da er operative Spielräume für geplante Eingriffe eröffnet und ungeplante Stillstände vermeidbar macht (vgl. **E2-24; E9-17**).

Eng damit verknüpft ist der von den Experten hervorgehobene Nutzen in der verbesserten Planbarkeit von Instandhaltungsmaßnahmen. Mehrere Interviewpartner betonen, dass datenbasierte Vorhersagen nicht primär als exakte Prognosen einzelner Ausfälle verstan-

den werden, sondern als Entscheidungsgrundlage für eine strukturierte Wartungsplanung dienen (vgl. **E2-40; E19-16**). Gerade aus operativer Perspektive wird dies als wesentlicher Fortschritt gegenüber rein reaktiven Vorgehensweisen beschrieben, da Wartungsfenster gezielter genutzt und Ressourcen effizienter eingesetzt werden können (vgl. **E1-16**).

Ein weiterer zentraler Nutzenaspekt liegt aus Sicht der Experten in der systematischen Erfassung und langfristigen Sicherung bislang stark personengebundenen Erfahrungswissens. In mehreren Interviews wird darauf hingewiesen, dass kritisches Domänenwissen häufig implizit vorliegt und nur eingeschränkt dokumentiert ist (vgl. **E2-12; E3-11; E4-23**). Dieses Wissensdefizit wird insbesondere im Kontext des demografischen Wandels und zunehmender Fluktuation als strukturelles Risiko wahrgenommen (vgl. **E2-16; E11-25**). Das Referenzmodell wird in diesem Zusammenhang als geeigneter Rahmen beschrieben, um Erfahrungswissen formal zu strukturieren, mit Betriebsdaten zu verknüpfen und für datengetriebene Analysen nutzbar zu machen. Die im Modell vorgesehene Wissenskomponente wird dabei nicht als optionales Zusatzmodul, sondern als grundlegende Voraussetzung für den sinnvollen Einsatz datenbasierter Verfahren bewertet (vgl. **E4-09; E13-25; E14-30**).

Darüber hinaus sehen die Interviewten einen wesentlichen Mehrwert in der Integration von Data-Mining-Methoden zur Mustererkennung und Anomaliedetektion. Insbesondere bei großen Datenmengen stoßen manuelle Auswertungen aus Expertensicht schnell an ihre Grenzen (vgl. **E1-20; E17-10; E18-07**). Die datengetriebenen Verfahren werden daher weniger als Ersatz menschlicher Expertise, sondern als notwendige Ergänzung zur Bewältigung der wachsenden Komplexität industrieller Produktionsdaten verstanden (vgl. **E9-19**). Mehrere Experten betonen, dass der eigentliche Nutzen nicht im einzelnen Analysemodell liege, sondern in der durchgängigen Verknüpfung von Datenerhebung, Analyse und Entscheidungsunterstützung innerhalb einer funktionierenden End-to-End-Pipeline (vgl. **E15/16-08; E18-17**).

Trotz der insgesamt positiven Bewertung verweisen die Experten wiederholt auf Bedingungen, die erfüllt sein müssen, damit sich der Nutzen des Referenzmodells in der Praxis entfalten kann. Als kritisch werden insbesondere der Aufwand für Datenaufbereitung und manuelles Labeling hervorgehoben, die als Engpass identifiziert werden (vgl. **E1-10; E3-07; E9-20; E17-10; E18-10**). Darüber hinaus werden organisatorische Faktoren wie Ressourcenverfügbarkeit und Veränderungsbereitschaft als entscheidend für den Erfolg datengetriebener Instandhaltungsansätze benannt (vgl. **E2-30; E7-18; E17-22**). Gleichwohl überwiegt aus Sicht der Interviewten die Einschätzung, dass der langfristige Nutzen des Referenzmodells den initialen Implementierungsaufwand übersteigt, sofern dessen Einführung schrittweise erfolgt und organisatorisch verankert wird (vgl. **E1-26; E8-16; E9-36; E11-28; E12-26; E15/16-22**).

Zusammenfassend zeigt sich über beide Erhebungsphasen hinweg ein konsistentes Bild. Das Referenzmodell wird von den Experten als ein geeigneter und praxisnaher Rahmen zur Weiterentwicklung datengetriebener Instandhaltungsstrategien wahrgenommen. Der Nutzen manifestiert sich dabei sowohl auf operativer Ebene in Form verbesserter Planbarkeit und reduzierter Stillstände als auch auf struktureller Ebene durch Wissenssicherung, methodische Ordnung und Skalierbarkeit der Analyseansätze (vgl. **E4-15; E9-17; E11-25; E19-14**).

7.2.2 Verständlichkeit und Zugänglichkeit

Die befragten Experten bewerten das Referenzmodell der intelligenten Data Pipeline als grundsätzlich schlüssig, konsistent und in seiner Grundstruktur gut nachvollziehbar. Insbesondere die klare Modularisierung, die transparente Trennung von Datenflüssen und Funktionsbereichen sowie die technologieunabhängige Ausgestaltung werden als wesentliche Faktoren für die Verständlichkeit hervorgehoben (vgl. **E1–E6; E5-18; E8-21; E11-10**). Aus Sicht der Interviewten trägt diese konzeptionelle Klarheit dazu bei, das Referenzmodell nicht als starres technisches Konstrukt, sondern als orientierenden Ordnungsrahmen für unterschiedliche Anwendungskontexte zu begreifen. Gerade im Hinblick auf die Übertragbarkeit auf andere Produktionsumgebungen und Unternehmensgrößen wird diese Offenheit als zentraler Vorteil bewertet.

Gleichzeitig zeigen die Experten deutlich auf, dass sich Verständnisgrenzen insbesondere dort ergeben, wo abstrakte oder technisch komplexe Modellbestandteile betroffen sind. Dies betrifft vor allem die Wissensdatenbank, domänenspezifische Labeling-Prozesse sowie die Integration von Data-Mining-Methoden zur Ableitung prädiktiver oder präskriptiver Handlungsempfehlungen (vgl. **E3-18; E5-20; E9-28**). Mehrere Interviewpartner machen deutlich, dass diese Komponenten zwar als inhaltlich sinnvoll und notwendig erachtet werden, ihre Funktionsweise jedoch ohne vertiefte Vorkenntnisse in Datenanalyse oder algorithmischer Modellierung nur eingeschränkt nachvollziehbar ist. Insbesondere die Logik datengetriebener Modelle, etwa im Hinblick auf Entscheidungsgrenzen, Gewichtungen oder Trainingsprozesse, wird als erklärungsbedürftig beschrieben.

Ein zentrales Spannungsfeld ergibt sich dabei aus der Diskrepanz zwischen technischer Leistungsfähigkeit und kognitiver Zugänglichkeit. Während das Referenzmodell in der Lage ist, komplexe Zustände automatisiert zu analysieren und daraus eine Entscheidungsunterstützung abzuleiten, verfügen viele potenzielle Anwender nicht über ausreichende Daten- oder Modellkompetenzen, um diese Ergebnisse kritisch einzuordnen (vgl. **E8-26-28; E9-33; E10-22**). Dies betrifft insbesondere Fragen danach, auf welchen Datenbasen Entscheidungen beruhen, wie Modelle trainiert werden und in welchem Umfang Unsicherheiten oder Modellgrenzen bestehen. Die Verständlichkeit wird damit nicht allein zu einer Eigenschaft des Modells selbst, sondern zu einer relationalen Größe, die wesentlich vom Vorwissen, der Rolle und dem Verantwortungsbereich der jeweiligen Nutzer abhängt.

Im Zusammenhang mit den Data-Mining-Komponenten wird zudem deutlich, dass ein grundsätzliches Interesse an deren Nutzen besteht, die konkrete Funktionsweise jedoch häufig abstrakt bleibt (vgl. **E2-26; E7-12**). Mehrere Interviewpartner äußern, dass zwar ein hohes Vertrauen in die Leistungsfähigkeit datengetriebener Verfahren vorhanden sei, dieses Vertrauen jedoch nicht zwingend auf einem detaillierten Verständnis der zugrunde liegenden Algorithmen beruhe (vgl. **E2-40; E3-36; E6-24; E18-27**). Damit berührt die Frage der Verständlichkeit unmittelbar Aspekte der Transparenz und Nachvollziehbarkeit, die aus Expertensicht eng mit der späteren Akzeptanz der Artefakte verknüpft sind. Vor diesem Hintergrund wird die Verständlichkeit des Referenzmodells von den Experten als kritischer Erfolgsfaktor für die praktische Anwendung datenbasierter Instandhaltungsansätze eingeschätzt. Eine nachhaltige Nutzung erscheint nur dann realistisch, wenn Anwender das Zusammenspiel von Sensordatenerfassung, Datenverarbeitung, Modellbildung und

Entscheidungsausgabe zumindest auf konzeptioneller Ebene nachvollziehen können (vgl. **E6-26; E9-19; E10-09; E12-19**). Daraus leiten die Interviewten den Bedarf ab, komplexe Modellbestandteile nicht nur funktional korrekt zu implementieren, sondern diese auch didaktisch aufzubereiten und durch geeignete Unterstützungsformate zu flankieren.

Insgesamt beschreiben die Experten die Verständlichkeit des Referenzmodells nicht als statische Eigenschaft, sondern als kontext- und nutzerabhängig. Je nach Qualifikationsniveau, Erfahrungshintergrund und organisationaler Rolle sind unterschiedliche Erklärungstiefen erforderlich (vgl. **E11-23-26; E18-25-26**). Das Referenzmodell selbst bietet mit seiner klaren Struktur eine tragfähige Grundlage für eine solche adaptive Vermittlung. Für die praktische Einführung wird empfohlen, insbesondere komplexe Analysekomponenten durch Visualisierungen, erklärende Metamodelle oder interaktive Demonstratoren zu ergänzen, um die Kluft zwischen algorithmischer Komplexität und menschlicher Entscheidungslogik nachhaltig zu überbrücken.

7.2.3 Anwendbarkeit und Reproduzierbarkeit

Die Anwendbarkeit des vorgestellten Referenzmodells der intelligenten Data Pipeline wird von den Interviewpartnern differenziert und kontextabhängig bewertet. Grundsätzlich wird sowohl die Umsetzung des Referenzmodells als auch der Einsatz der in den Fallstudien betrachteten Data-Mining-Methoden in realen Produktionsumgebungen als möglich und sinnvoll eingeschätzt (vgl. **E2-30; E4-23**). Zugleich machen die Experten deutlich, dass die praktische Realisierung an eine Reihe technischer, organisatorischer und infrastruktureller Voraussetzungen geknüpft ist, die den Erfolg der Implementierung maßgeblich beeinflussen (vgl. **E5-22; E8-28**).

Ein zentraler Aspekt der Anwendbarkeit betrifft die technische Realisierbarkeit, insbesondere im Hinblick auf Datenverfügbarkeit, Datenqualität und Datenintegration (vgl. **E8-17; E17-08**). Mehrere Experten berichten aus der betrieblichen Praxis, dass die automatisierte Erfassung und nutzbare Aufbereitung von Maschinendaten in bestehenden Produktionsumgebungen mit erheblichem Aufwand verbunden sein kann (vgl. **E1-20; E3-26; E4-35; E18-08**). Insbesondere bei älteren Anlagen, heterogenen Steuerungssystemen oder proprietären Datenformaten wird die Datenanbindung als aufwendig beschrieben (vgl. **E5-28; E9-25; E12-22**). Die Konvertierung von Maschinendaten in analysierbare Strukturen sowie die Vereinheitlichung unterschiedlicher Datenquellen binden aus Expertensicht signifikante personelle und zeitliche Ressourcen. Vor diesem Hintergrund wird die im Referenzmodell vorgesehene Fähigkeit zur datenquellenübergreifenden Integration als zentraler Erfolgsfaktor für die praktische Anwendbarkeit bewertet (vgl. **E11-20-21; E12-22-23**). Die Unterstützung standardisierter Schnittstellen und die Möglichkeit, unterschiedliche Datenformate systematisch zusammenzuführen, werden als notwendige Voraussetzung für einen nachhaltigen produktiven Einsatz hervorgehoben (vgl. **E4-29; E13-16; E14-13; E15/16-17; E19-22**). Gleichzeitig wird deutlich, dass die technische Anwendbarkeit weniger von einzelnen Analyseverfahren abhängt als vielmehr von der Stabilität und Durchgängigkeit der gesamten Datenpipeline (vgl. **E17-12; E18-17**). Ergänzend verweisen die Interviewten auf die Bedeutung geeigneter Rechenressourcen. Je nach Komplexität der eingesetzten Modelle und Datenmengen kann ein erhöhter Bedarf an Rechenleistung entstehen, der

nicht in allen Produktionsumgebungen ohne Weiteres verfügbar ist (vgl. **E2-30; E9-21**). Mehrere Experten betonen daher die Notwendigkeit, zwischen Edge-naher Verarbeitung und zentralen Analyseplattformen abzuwägen und Aspekte wie Latenz, Datenschutz, Betriebskosten und Wartbarkeit in die Architekturentscheidung einzubeziehen (vgl. **E4-25; E13-18; E14-25; E15/16-11**).

Neben der technischen Machbarkeit identifizieren die Experten die organisatorische Einbettung als einen entscheidenden Faktor für die praktische Anwendbarkeit des Referenzmodells. Die Einführung datengetriebener Instandhaltungsansätze wird wiederholt als Eingriff in bestehende Prozesse, Rollenbilder und Verantwortungsstrukturen beschrieben (vgl. **E5-24; E6-24; E8-23; E9-34; E10-21; E13-28**). Insbesondere an den Schnittstellen zwischen Instandhaltung, IT und Data Science entstehen neue Abstimmungsbedarfe, die organisatorisch adressiert werden müssen (vgl. **E15/16-24**). Mehrere Interviewpartner berichten von Vorbehalten innerhalb der Belegschaft, insbesondere wenn algorithmisch erzeugte Handlungsempfehlungen als potenzielle Konkurrenz zum erfahrungsbasierten Wissen wahrgenommen werden (vgl. **E3-36; E4-33; E5-25; E8-28; E9-31**). Diese kulturelle Dimension wird von den Experten als nicht zu unterschätzende Hürde für die Anwendbarkeit eingeschätzt. Gleichzeitig wird betont, dass Akzeptanz und praktische Nutzbarkeit deutlich steigen, wenn das Referenzmodell nicht als Ersatz, sondern als Unterstützung bestehender Expertise eingeführt wird und Domänenexperten aktiv in Entwicklung und Betrieb eingebunden sind (vgl. **E3-34; E7-20 E9-33; E19-34**). Vor diesem Hintergrund empfehlen die Interviewten ein schrittweises, iteratives Vorgehen bei der Implementierung. Pilotanwendungen in klar abgegrenzten Teilbereichen ermöglichen es, erste Erfolge sichtbar zu machen, Vertrauen aufzubauen und das Referenzmodell sukzessive in bestehende Produktionsstrukturen zu integrieren (vgl. **E5-30; E12-26; E15/16-28 E19-33**). Besonders hervorgehoben wird die frühzeitige Einbindung von Instandhaltungspersonal, um sowohl technische als auch anwendungsnahe Anforderungen angemessen zu berücksichtigen (vgl. **E7-20; E14-30**).

Ein weiterer, wiederholt genannter Einflussfaktor auf die Anwendbarkeit betrifft die personelle Ausstattung und Qualifikation. Mehrere Experten weisen darauf hin, dass der nachhaltige Betrieb datengetriebener Systeme entsprechendes Fachwissen erfordert, sowohl im Bereich der Domäne als auch im Umgang mit Daten, Modellen und IT-Systemen (vgl. **E9-25; E12-19; E17-22;**). Fehlen diese Kompetenzen, wird die langfristige Praktikabilität des Referenzmodells als eingeschränkt bewertet. Auch ökonomische Aspekte fließen in die Einschätzung der Anwendbarkeit ein. Zwar standen Investitionskosten nicht im Zentrum der Evaluation, dennoch verweisen mehrere Interviewte auf Aufwände, die bei der Einführung berücksichtigt werden müssen (vgl. **E4-25; E8-19; E12-15;**). Gleichzeitig betonen die Experten, dass eine rein kurzfristige Kostenbetrachtung dem Nutzen datengetriebener Instandhaltungsansätze nicht gerecht werde. Insbesondere indirekte Effekte wie reduzierte Stillstandszeiten, verbesserte Planbarkeit oder gesicherter Wissensbestand werden als zentrale Nutzenkomponenten genannt, die in eine umfassende Wirtschaftlichkeitsbetrachtung einfließen sollten (vgl. **E7-24; E13-24; E11-25; E12-28**).

Zusammenfassend zeigt sich, dass das Referenzmodell der intelligenten Data Pipeline aus Sicht der Experten grundsätzlich praktikabel in der Produktionsdomäne einsetzbar

ist, sofern geeignete technische, organisatorische und personelle Rahmenbedingungen geschaffen werden. Die Anwendbarkeit ist dabei stark kontextabhängig und weniger eine Eigenschaft einzelner Modellkomponenten als vielmehr das Ergebnis eines bewusst gesteuerten Implementierungsprozesses. Die Experten empfehlen ein anwendungsnahes, iteratives Vorgehen, das technische Machbarkeit, organisatorische Anschlussfähigkeit und kulturelle Akzeptanz gleichermaßen berücksichtigt. Unter diesen Voraussetzungen wird das Referenzmodell als tragfähige Grundlage für den produktiven Einsatz datengetriebener Instandhaltungsstrategien bewertet.

7.2.4 Übertragbarkeit und Skalierbarkeit

Die befragten Experten bescheinigen dem Referenzmodell der intelligenten Data Pipeline ein hohes Maß an Übertragbarkeit und Skalierbarkeit über die ursprünglich betrachtete Produktionsdomäne hinaus. Das Modell wird dabei nicht als domänenspezifische Einzellösung verstanden, sondern als abstraktes, technologisch offenes Rahmenkonzept, das grundlegende Prinzipien datengetriebener Instandhaltung systematisch abbildet und damit grundsätzlich auf unterschiedliche industrielle Kontexte anwendbar ist (vgl. **E2-34**; **E3-30**; **E4-27**; **E8-31**; **E15/16-05**; **E19-39-40**). Die Übertragbarkeit bezieht sich dabei weniger auf konkrete technische Ausprägungen als vielmehr auf die zugrunde liegende funktionale Logik des Modells.

Zentral für die Einschätzung der Übertragbarkeit ist aus Expertensicht die im Referenzmodell verankerte zyklische Grundstruktur aus Datenerfassung, Analyse und Ableitung von Handlungsempfehlungen (vgl. **E1-22**; **E2-26**). Diese Logik wird als domänenunabhängig bewertet, sofern Produktionssysteme durch stabile, wiederkehrende Prozessmuster gekennzeichnet sind und kontinuierlich relevante Prozessdaten generieren (vgl. **E6-28**; **E10-23-24**; **E12-23**; **E17-17**). Entsprechend sehen die Interviewten ein hohes Übertragungspotenzial insbesondere in Produktionsbereichen mit zyklischen Bewegungsabläufen, standardisierten Bearbeitungsschritten oder deterministischen Materialflüssen, wie sie etwa in der Fördertechnik, der Kunststoffverarbeitung, der Lackiererei oder in robotergestützten Montageprozessen auftreten (vgl. **E3-26**; **E5-26**; **E9-27**).

Die Übertragbarkeit erstreckt sich dabei sowohl auf das Referenzmodell als konzeptionellen Ordnungsrahmen als auch auf die exemplarisch eingebetteten Fallstudien. Die Experten interpretieren diese Fallstudien nicht als domänenspezifische Sonderlösungen, sondern als abstrahierte Repräsentationen technologischer Funktionsprinzipien, die mit entsprechenden Anpassungen auf andere technische Systeme übertragen werden können (vgl. **E22-36**; **E5-28**, **E8-31**; **E14-14**; **E15/16-18**). Die Fallstudien fungieren damit weniger als Blaupause im Sinne einer direkten Wiederverwendung, sondern als methodische Vorlage für eine systematische Skalierung auf vergleichbare technische Kontexte (vgl. **E17-26**; **E18-30**). Dies wird insbesondere am Beispiel linearer Bewegungsmechaniken deutlich. Die in den Fallstudien betrachteten Zahnstangenantriebe werden von den Experten nicht als singuläre Anwendung interpretiert, sondern als Repräsentanten eines übergeordneten Bewegungsprinzips, das in zahlreichen Produktionsbereichen Anwendung findet (vgl. **E3-30**; **E4-27**). Vergleichbare translatorische Bewegungsmuster treten etwa bei Montagebändern, Handhabungssystemen oder Roboterachsen auf, unabhängig davon,

ob diese durch Zahnstangen, Riemenantriebe oder Spindelmechaniken realisiert werden. Die Übertragbarkeit ergibt sich somit nicht aus dem konkreten Antriebstyp, sondern aus der Möglichkeit, analoge Prozessparameter zu erfassen, zu analysieren und in Beziehung zu setzen. Ein vergleichbares Argumentationsmuster zeigt sich bei den im Rahmen der Fallstudien betrachteten Druckluftgreifern. Die zugrunde liegende pneumatische Wirkweise wird von den Experten als in der industriellen Praxis weit verbreitet beschrieben und findet sich in unterschiedlichen Produktionsdomänen wieder (vgl. **E5-14**; **E8-30**; **E18-19**). Die Möglichkeit, Druckverläufe, Taktzeiten oder Zustandsänderungen sensorisch zu erfassen und datengetrieben auszuwerten, wird als grundlegendes Prinzip verstanden, das unabhängig vom konkreten Einsatzfeld Anwendung finden kann. Eine stärkere Domänenspezifika weisen aus Sicht der Interviewten die Fallstudie zum Ziehkissen auf, die primär im Umfeld der Umformtechnik eingesetzt werden (vgl. **E3-16**). Gleichwohl wird auch hier ein Übertragungspotenzial gesehen, sofern vergleichbare Prozessmerkmale (vgl. **E12-12**; **E14-13**). Entscheidend ist für Data-Mining-Anwendungen aus Expertensicht nicht die Maschine als solche, sondern das Vorhandensein zyklischer, mechanisch determinierter Prozesse mit messbaren Soll-Ist-Abweichungen, die eine datengetriebene Analyse ermöglichen (vgl. **E18-17**; **E19-14**).

Neben der technischen Übertragbarkeit thematisieren die Experten die Skalierbarkeit des Referenzmodells ausdrücklich als eigenständige, architektonisch begründete Eigenschaft. Skalierbarkeit wird dabei weniger als bloße Vervielfältigung einzelner Analysemodelle verstanden, sondern als die Fähigkeit, datengetriebene Instandhaltungslogiken effizient über mehrere Maschinen, Produktionsbereiche und Standorte hinweg auszurollen (vgl. **E1-12**; **E10-14-15**; **E11-17**; **E12-14**; **E14-23**; **E15/16-17**; **E19-18-20**). In diesem Zusammenhang messen die Interviewten insbesondere der im Referenzmodell vorgesehenen Cloud-Komponente eine zentrale Bedeutung bei. Die Cloud wird von den Experten als wesentlicher Enabler für Skalierung beschrieben, da sie die zentrale Bereitstellung, Verwaltung und Weiterentwicklung von Analysemodellen ermöglicht. Anstatt Modelle an jedem Standort separat zu entwickeln, zu trainieren und zu warten, können einmal validierte Modelle zentral vorgehalten und standortübergreifend wiederverwendet werden (vgl. **E8-32**; **E11-17**; **E12-15-17**; **E13-25**; **E14-23-24**; **E15/16-19**). Dies reduziert nicht nur den initialen Entwicklungsaufwand, sondern erhöht zugleich die Konsistenz der angewendeten Analyseverfahren über unterschiedliche Produktionsumgebungen hinweg. Skalierung wird damit nicht als lokales Hochfahren von Rechenleistung verstanden, sondern als organisatorisch und architektonisch kontrollierte Verbreitung standardisierter Analysebausteine. Mehrere Experten betonen, dass gerade in konzernweiten Produktionsstrukturen die Möglichkeit, Modelle zentral zu betreiben und auszurollen, einen entscheidenden Unterschied gegenüber rein lokalen Lösungen darstellt (vgl. **E10-15**; **E12-16**; **E13-24**). Die Cloud fungiert dabei als Träger einer übergeordneten Modell- und Wissensebene, während die standortspezifischen Komponenten, insbesondere Datenerfassung und Vorverarbeitung, lokal verbleiben. Diese Trennung erlaubt es, standortübergreifende Skaleneffekte zu realisieren, ohne die jeweiligen betrieblichen Besonderheiten vollständig zu nivellieren.

Gleichzeitig benennen die Experten klare Grenzen der Übertragbarkeit und Skalierbarkeit datengetriebener Instandhaltungsansätze. Eine häufig genannte Einschränkung betrifft

den Zustand der technischen Infrastruktur, insbesondere bei älteren Anlagen, bei denen relevante Messpunkte fehlen oder nur mit erheblichem Aufwand nachrüstbar sind (vgl. **E3-32; E5-22; E6-22; E10-22-23; E11-20; E12-22**). In solchen Fällen wird die prinzipielle Übertragbarkeit der Modelllogik zwar nicht grundsätzlich in Frage gestellt, der erforderliche Implementierungsaufwand steigt jedoch deutlich. Ähnliches gilt für stark heterogene oder individualisierte Anlagenkonfigurationen, bei denen die Vergleichbarkeit von Daten eingeschränkt ist und zusätzlicher Aufwand im Feature Engineering oder beim domänenspezifischen Nachtrainieren von Modellen erforderlich wird (vgl. **E1-10; E3-07; E9-20-21**). Darüber hinaus heben die Interviewten hervor, dass technische Übertragbarkeit und architektonische Skalierbarkeit nicht automatisch mit wirtschaftlicher Vorteilhaftigkeit gleichzusetzen sind. In Produktionsbereichen mit geringen Ausfallkosten, hoher Prozessrobustheit oder stark manuellen Tätigkeiten kann der potenzielle Nutzen datengetriebener Vorhersagemodelle als zu gering eingeschätzt werden, um die notwendigen Investitionen in Infrastruktur, Qualifikation und Betrieb zu rechtfertigen (vgl. **E8-19; E10-20**). Skalierbarkeit wird daher nicht als universelles Ziel verstanden, sondern als kontextabhängige strategische Entscheidung, die eine Abwägung zwischen Standardisierungspotenzial und lokalem Mehrwert erfordert.

Vor diesem Hintergrund verdeutlichen die Experten, dass Skalierbarkeit nicht ausschließlich eine technische Eigenschaft des Referenzmodells darstellt. Die Wiederverwendbarkeit zentral bereitgestellter Modelle voraus, dass zugrunde liegende Prozessstrukturen, Sensorkonzepte und Datenqualitäten hinreichend vergleichbar sind (vgl. **E14-13-14; E19-25**). Wo diese Voraussetzungen nicht erfüllt sind, verschiebt sich Skalierbarkeit von einer unmittelbaren Wiederverwendung hin zu einer graduellen Anpassung, die zusätzliche domänenspezifische Modellierungsschritte erfordert. Skalierbarkeit wird damit als balanciertes Zusammenspiel aus Standardisierung und kontextspezifischer Adaption verstanden. Zugleich verknüpfen die Interviewten die Skalierbarkeit des Referenzmodells explizit mit organisatorischen Fragestellungen. Die zentrale Bereitstellung von Analysemodellen über eine Cloud-Infrastruktur impliziert neue Rollenverteilungen zwischen lokalen Instandhaltungseinheiten und zentralen IT- oder Data-Science-Teams (vgl. **E9-34; E11-26; E17-22; E19-29**). Nachhaltige Skalierung erfordert aus Expertensicht klare Verantwortlichkeiten für Modellpflege, Versionierung und Qualitätssicherung. In diesem Sinne fungiert die Cloud nicht nur als technische Infrastruktur, sondern als organisatorischer Kristallisationspunkt einer datengetriebenen Instandhaltungsstrategie.

Zusammenfassend bestätigen die Experten, dass das Referenzmodell der intelligenten Data Pipeline eine übergeordnete funktionale Systematik abbildet, die sowohl Übertragbarkeit als auch Skalierbarkeit datengetriebener Instandhaltungsansätze unterstützt. Diese Systematik erlaubt eine kontextsensitive Adaption der Modelllogik auf unterschiedliche Maschinen, Prozesse und Produktionsdomänen, ohne die grundlegende Struktur des Referenzmodells zu verändern. Das Modell wird damit nicht als starre Blaupause verstanden, sondern als flexible Orientierungsstruktur, die je nach technischer Ausstattung, organisatorischem Reifegrad und wirtschaftlichem Kontext angepasst werden muss, um ihre Wirksamkeit nachhaltig zu entfalten.

7.2.5 Akzeptanz

Die Bewertung der potenziellen Akzeptanz des Referenzmodells der intelligenten Data Pipeline sowie der darauf aufbauenden Data-Mining-Anwendungen fällt aus Sicht der befragten Experten differenziert aus. Grundsätzlich besteht eine hohe Offenheit gegenüber datenbasierten Instandhaltungsansätzen, insbesondere vor dem Hintergrund zunehmender Anlagenkomplexität und steigender Anforderungen an Verfügbarkeit und Effizienz. Gleichzeitig machen die Interviewten deutlich, dass Akzeptanz in der Anwendungspraxis nicht als automatische Folge technischer Leistungsfähigkeit verstanden werden kann, sondern gezielt aufgebaut, begleitet und organisatorisch verankert werden muss (vgl. **E1-24; E2-32; E3-34; E8-26; E9-33**).

Ein zentrales Akzeptanzkriterium stellt das Vertrauen in algorithmisch generierte Handlungsempfehlungen dar. Mehrere Experten betonen, dass erfahrene Instandhalter insbesondere zu Beginn skeptisch gegenüber automatisierten Vorschlägen reagieren können, vor allem dann, wenn diese im Widerspruch zu etablierten Erfahrungswerten stehen oder nicht hinreichend nachvollziehbar sind (vgl. **E2-40; E3-36; E5-24; E6-26**). Fehlprognosen oder nicht erklärbare Empfehlungen werden in diesem Zusammenhang als besonders kritisch eingeschätzt, da sie das Vertrauen in das Gesamtsystem nachhaltig beeinträchtigen können. Die Akzeptanz hängt daher maßgeblich von der wahrgenommenen Verlässlichkeit der Modelle sowie von der Transparenz ihrer Entscheidungslogik ab (vgl. **E4-33; E8-28; E18-27**).

Darüber hinaus zeigen die Interviews, dass Akzeptanz stark rollen- und erfahrungsabhängig ausgeprägt ist. Während jüngere Mitarbeitende oder Beschäftigte mit hoher Digitalisierungsaffinität datengetriebenen Systemen tendenziell offener gegenüberstehen, äußern erfahrene Fachkräfte mit ausgeprägtem Domänenwissen häufiger Vorbehalte (vgl. **E3-34; E2-32; E6-24; E9-31; E11-25**). Diese Zurückhaltung wird weniger als grundsätzliche Technikablehnung interpretiert, sondern vielmehr als Ausdruck der Sorge, dass implizites Erfahrungswissen entwertet oder durch nicht nachvollziehbare algorithmische Logiken ersetzt werden könnte. Akzeptanz ist damit eng mit Fragen der professionellen Identität, Autonomie und Verantwortungszuschreibung verknüpft.

Die Art und Weise der Systemintegration in den Arbeitsalltag erweist sich als weiterer zentraler Einflussfaktor. Systeme, die Handlungsempfehlungen klar strukturiert, verständlich und kontextbezogen kommunizieren, werden von den Experten als unterstützend wahrgenommen und können zur kognitiven Entlastung der Anwender beitragen (vgl. **E1-16; E10-22; E19-34**). Gleichzeitig wird hervorgehoben, dass datengetriebene Anwendungen insbesondere weniger erfahrene Mitarbeitende befähigen können, standardisierte Instandhaltungsmaßnahmen sicher durchzuführen. Dieser Kompetenzgewinn wird in personell angespannten Bereichen als klarer Vorteil bewertet (vgl. **E2-24; E3-11; E11-25**). Zugleich wird darauf hingewiesen, dass genau dieser Effekt bei hochqualifizierten Fachkräften auch Befürchtungen hinsichtlich eines Bedeutungsverlusts der eigenen Rolle auslösen kann, wenn die Systeme nicht als ergänzend, sondern als ersetzend wahrgenommen werden (vgl. **E9-31**).

Mehrere Interviewpartner betonen daher die zentrale Bedeutung eines begleitenden Change-Managements für die nachhaltige Akzeptanz datengetriebener Instandhaltungsan-

sätze. Als förderlich gelten insbesondere die frühzeitige Einbindung der Anwender, eine transparente Kommunikation der Zielsetzung und Funktionsweise der Systeme sowie die Möglichkeit, den Nutzen anhand konkreter, nachvollziehbarer Anwendungsfälle zu erleben (vgl. **E2-32**; **E3-34**; **E7-20**; **E9-33**; **E19-30**). Positiv hervorgehobene Erfahrungen, etwa durch zuverlässig vorhergesagte Ausfälle oder vermiedene Stillstände, werden als entscheidend für den schrittweisen Vertrauensaufbau beschrieben. Akzeptanz entsteht aus Expertensicht somit nicht punktuell, sondern als iterativer Prozess, der durch Schulungsmaßnahmen, kontinuierliche Systemvalidierung und Rückkopplung mit der Praxis unterstützt werden muss.

Neben individuellen Faktoren spielt auch die organisationale Einbettung eine wesentliche Rolle. Die Interviewten weisen darauf hin, dass datengetriebene Systeme nur dann nachhaltig akzeptiert werden, wenn sie durch ein klares organisatorisches Commitment getragen werden (vgl. **E2-32**; **E6-22**; **E13-28**; **E15/16-20**; **E19-16**). Fehlende Unterstützung durch das Management, unklare Verantwortlichkeiten oder unzureichende Ressourcen können selbst technisch funktionierende Lösungen scheitern lassen. In mehreren Interviews wird berichtet, dass Projekte trotz prinzipieller Machbarkeit eingestellt wurden, weil es an langfristiger organisatorischer Verankerung oder an aktiven Fürsprechern innerhalb der Organisation fehlte (vgl. **E8-26**; **E10-20**; **E14-21**).

Insgesamt verdeutlichen die Experten, dass die Akzeptanz des Referenzmodells und der darauf aufbauenden Data-Mining-Anwendungen weniger von deren technischer Leistungsfähigkeit als vielmehr von sozialen, kulturellen und kommunikativen Faktoren abhängt. Eine erfolgreiche Einführung setzt voraus, dass potenzielle Widerstände ernst genommen, Rollenbilder reflektiert und der konkrete Anwendungsnutzen nachvollziehbar vermittelt werden. Die Implementierung des Referenzmodells ist damit als sozio-technischer Transformationsprozess zu verstehen, dessen Gelingen maßgeblich von der aktiven Beteiligung, dem Vertrauen und der langfristigen Unterstützung der betroffenen Akteure abhängt.

7.2.6 Querschnittliche Muster und Deutungszusammenhänge

Die querschnittliche Analyse der Experteninterviews zeigt, dass die fünf Evaluationskriterien Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Akzeptanz nicht unabhängig voneinander wirksam werden, sondern sich in einem wechselseitig bedingenden Zusammenhang entfalten. Die Tragfähigkeit des entwickelten Referenzmodells ergibt sich somit nicht aus der isolierten Erfüllung einzelner Kriterien, sondern aus deren kumulativer und relationaler Ausprägung im jeweiligen Anwendungskontext. Im Folgenden werden die zentralen Deutungsmuster entlang der Evaluationskriterien analysiert und zueinander in Beziehung gesetzt.

Die **Nützlichkeit** wird von den Experten querschnittlich als inhärente Eigenschaft des Referenzmodells anerkannt. Insbesondere der Beitrag zur kausal-prädiktiven Instandhaltung, zur Reduktion ungeplanter Stillstände sowie zur systematischen Nutzung und Sicherung impliziten Erfahrungswissens wird konsistent hervorgehoben. Analytisch bedeutsam ist jedoch, dass Nützlichkeit nicht als automatisch wirksamer Effekt verstanden wird, sondern als potenzielles Nutzenversprechen, dessen Realisierung an konkrete Nutzungs- und Implementationsbedingungen geknüpft ist. Der Nutzen des Modells entfaltet sich dem-

nach nicht durch seine bloße Existenz, sondern erst durch seine tatsächliche Einbettung in operative Entscheidungs- und Instandhaltungsprozesse. Damit fungiert Nützlichkeit als notwendige, jedoch nicht hinreichende Bedingung für den praktischen Mehrwert des Artefakts.

Die **Verständlichkeit** des Referenzmodells erweist sich in der querschnittlichen Betrachtung als zentrale Vermittlungsgröße zwischen technischer Leistungsfähigkeit und praktischer Nutzung. Während die strukturelle Logik, Modularisierung und technologische Offenheit des Modells überwiegend als nachvollziehbar beschrieben werden, treten Verständnishürden insbesondere bei datenanalytischen und algorithmischen Komponenten auf. Die Interviews zeigen, dass Verständlichkeit nicht als objektive Systemeigenschaft zu begreifen ist, sondern stark von Rolle, Qualifikationsniveau und Datenkompetenz der Anwender abhängt. Analytisch lässt sich festhalten, dass mangelnde Transparenz algorithmischer Entscheidungslogiken nicht nur die Nutzung erschwert, sondern mittelbar auch die Akzeptanz untergräbt. Verständlichkeit wirkt damit als Schlüsselkriterium, das entscheidet, ob Nützlichkeit überhaupt erfahrbar und handlungswirksam wird.

In Bezug auf die **Anwendbarkeit** verdichtet sich in den Interviews ein Verständnis von Praktikabilität als prozesshaftem und kontextabhängigem Zustand. Das Referenzmodell wird grundsätzlich als umsetzbar eingeschätzt, jedoch nicht im Sinne einer sofortigen, vollumfänglichen Implementierung. Vielmehr wird Anwendbarkeit als Ergebnis eines schrittweisen, iterativen Einführungsprozesses beschrieben, der technische, organisatorische und kulturelle Voraussetzungen integriert. Die modulare Architektur des Referenzmodells tritt hierbei als zentraler Ermöglichungsfaktor hervor, da sie eine Anpassung an unterschiedliche Reifegrade von Dateninfrastruktur, Kompetenzen und Organisationsstrukturen erlaubt. Analytisch zeigt sich, dass Anwendbarkeit nicht unabhängig von Verständlichkeit und Akzeptanz betrachtet werden kann. Dabei wirken fehlende Transparenz oder mangelnde Akzeptanz direkt auf die praktische Nutzbarkeit zurück und können selbst technisch realisierbare Lösungen faktisch blockieren.

Die **Übertragbarkeit** des Referenzmodells wird in der querschnittlichen Analyse primär auf der Ebene funktionaler Abstraktion verortet. Die Experten erkennen im Modell keinen domänenspezifischen Sonderfall, sondern einen konzeptionellen Ordnungsrahmen, der grundlegende Prinzipien zyklischer Datenerfassung, Analyse und Entscheidungsunterstützung abbildet. Diese Abstraktion ermöglicht die Übertragung auf unterschiedliche Produktionsdomänen, sofern vergleichbare Prozess- und Datenstrukturen vorliegen. Gleichzeitig werden klare Grenzen der Übertragbarkeit benannt, etwa durch heterogene Anlagenlandschaften, fehlende Sensorik oder stark variierende Datenqualitäten. Analytisch wird deutlich, dass Übertragbarkeit nicht als Eigenschaft einzelner Modelle zu verstehen ist, sondern als Fähigkeit des Gesamtsystems, domänenspezifische Anpassungen systematisch zu integrieren, ohne die grundlegende Modelllogik zu verlieren. Weiterführend tritt die Skalierbarkeit in den Interviews als eigenständige, jedoch eng mit der Übertragbarkeit verknüpfte Dimension hervor. Sie wird weniger auf der Ebene einzelner Maschinen oder Standorte verortet, sondern auf der Ebene der Architektur und Organisation. Insbesondere die im Referenzmodell vorgesehene Cloud-Komponente wird als zentraler Skalierungsmechanismus beschrieben, da sie die zentrale Bereitstellung, Versionierung und Wiederverwendung

validierter Modelle ermöglicht. Skalierbarkeit wird damit nicht als rein technische Vervielfältigung lokaler Lösungen verstanden, sondern als kontrollierter Roll-out standardisierter Analyse- und Entscheidungslogiken über mehrere Produktionsstandorte hinweg. Analytisch lässt sich daraus ableiten, dass Skalierbarkeit nicht ohne organisatorische Governance, klare Verantwortlichkeiten und vergleichbare Prozessstandards realisierbar ist.

Die **Akzeptanz** des Referenzmodells wird in der querschnittlichen Betrachtung nicht als unabhängige Haltung, sondern als Resultat der zuvor genannten Kriterien rekonstruiert. Akzeptanz entsteht dort, wo Nützlichkeit erfahrbar, Verständlichkeit gegeben und Anwendbarkeit im Arbeitsalltag erlebbar wird. Die Interviews verdeutlichen, dass Vertrauen in datenbasierte Systeme ein iterativer Prozess ist, der durch Transparenz, Zuverlässigkeit und sichtbare Nutzungserfolge gestützt werden muss. Fehlende Akzeptanz wirkt dabei nicht nur als soziale Barriere, sondern entfaltet direkte Rückwirkungen auf Anwendbarkeit und Nutzenrealisierung. Akzeptanz fungiert somit als stabilisierendes Element des Gesamtsystems, dessen Ausprägung maßgeblich über die nachhaltige Wirksamkeit des Referenzmodells entscheidet.

Zusammenfassend zeigt die querschnittliche Analyse, dass das entwickelte Referenzmodell seine Stärke nicht in der isolierten Optimierung einzelner Kriterien, sondern in der strukturierten Verbindung von Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Skalierbarkeit entfaltet. Die Interviews legen nahe, dass datengetriebene Instandhaltungsansätze insbesondere dann scheitern, wenn diese Kriterien getrennt voneinander betrachtet oder ausschließlich technisch adressiert werden. Das Referenzmodell begegnet dieser Problematik, indem es eine modulare, abstrahierte und skalierbare Orientierungsstruktur bereitstellt, die technische, organisatorische und soziale Dimensionen systematisch integriert. Darüber hinaus verdeutlichen die Experteneinschätzungen, dass die im Rahmen der Fallstudien umgesetzten kausal-prädiktiven Analyseansätze einen wichtigen Zwischenschritt auf dem Weg zu weiterführenden präskriptiven Instandhaltungsstrategien darstellen. Die Fallbeispiele werden dabei nicht als abgeschlossene Lösungen verstanden, sondern als anwendungsnahe Demonstratoren, mit denen belastbares Prozess-, Zustands- und Wirkungswissen aufgebaut werden kann. Dieses Wissen bildet aus Sicht der Experten eine zentrale Voraussetzung für spätere präskriptive Entscheidungsmodelle, da belastbare Handlungsempfehlungen nur auf Grundlage hinreichend verstandener Ursache-Wirkungs-Zusammenhänge und valider Prognosen abgeleitet werden können. Analytisch lässt sich daraus ableiten, dass der Mehrwert des Referenzmodells nicht allein in der unmittelbaren Unterstützung prädiktiver Instandhaltung liegt, sondern in seiner Fähigkeit, eine konsistente Wissensbasis zu etablieren, auf der präskriptive Ansätze systematisch aufbauen können. Die kausal-prädiktiven Analysen fungieren in diesem Zusammenhang als vermittelnde Ebene zwischen datenbasierter Zustandsbewertung und handlungsorientierter Entscheidungsunterstützung. Gerade diese schrittweise Entwicklungsperspektive wird von den Experten als realistisch, anschlussfähig und praxisnah bewertet und unterstreicht den Charakter des Referenzmodells als entwicklungsfähigen Bezugsrahmen für datengetriebene Instandhaltungsstrategien.

7.3 Anforderungsabgleich auf Basis der Evaluation

Die in den vorangegangenen Abschnitten dargestellte Ergebnisauswertung der Experteninterviews sowie die querschnittliche Analyse der Deutungszusammenhänge liefern eine differenzierte empirische Einschätzung der Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Akzeptanz des entwickelten Referenzmodells aus Sicht der industriellen Praxis. Aufbauend auf diesen Ergebnissen erfolgt im vorliegenden Abschnitt eine systematische Rückspiegelung der Evaluation auf die in **Kapitel 5.9** abgeleitete Anforderungsmatrix.

Ziel dieses Schrittes ist es, die ursprünglich *ex ante* formulierten Designanforderungen mit den im Rahmen der Experteninterviews erhobenen Praxiseinschätzungen in Beziehung zu setzen. Während in **Kapitel 6.5** im Rahmen der Demonstration ein systematischer Abgleich zwischen Anforderungsdefinition und Artefaktausprägung anhand eines konkreten industriellen Anwendungskontexts vorgenommen wurde, erweitert die vorliegende Betrachtung diese artefaktnahe Perspektive um zusätzliche Einschätzungen aus unterschiedlichen Produktionsumgebungen, Organisationsformen und Reifegraden der Digitalisierung. Durch die gezielte Auswahl von Experten aus verschiedenen Werken, Domänen und Verantwortungsebenen wird die Evaluation damit nicht vertieft, sondern bewusst verbreitert, um die Anwendbarkeit, Übertragbarkeit und Skalierbarkeit des Referenzmodells über den ursprünglichen Demonstrationskontext hinaus zu reflektieren.

Der Fokus liegt dabei nicht auf einer erneuten Bewertung einzelner Interviewaussagen, sondern auf einer verdichteten Analyse, inwieweit sich die im Entwicklungsprozess getroffenen Designentscheidungen aus Sicht der Praxis bestätigen, relativieren oder kontextabhängig einschränken lassen. Durch die Gegenüberstellung von Anforderungsdefinition, Demonstrationsergebnissen und Experteneinschätzungen wird eine konsistente Bewertung des Referenzmodells entlang seines gesamten Entwicklungs- und Evaluationszyklus ermöglicht. Dieser Schritt schließt den Evaluationsprozess im Sinne des DSR-Ansatzes ab, indem er die Brücke zwischen konzeptioneller Anforderungsableitung, artefaktbezogener Demonstration und empirischer Evaluation schlägt (vgl. **Kapitel 2.3.2**). Die Rückspiegelung dient damit zugleich der kritischen Einordnung des erreichten Erfüllungsgrades der Anforderungen sowie der Identifikation von Spannungsfeldern und Weiterentwicklungspotenzialen, die sich aus der praktischen Anwendung ergeben.

Die in **Tabelle 16** dargestellte Rückspiegelung basiert auf einer systematischen Verdichtung der in **Kapitel 7.2** ausgewerteten Experteninterviews. Für jede Anforderung (R1–R14) wurden die zentralen, wiederkehrenden Aussagen der Interviewten hinsichtlich Anwendbarkeit, Übertragbarkeit und Skalierbarkeit zusammengeführt und mit dem in **Kapitel 6** dokumentierten Umsetzungsstand in Beziehung gesetzt. Die Einordnung erfolgt dabei nicht als erneute Bewertung des Artefakts, sondern als interpretative Zusammenfassung, inwiefern sich die im Entwicklungs- und Demonstrationskontext getroffenen Designentscheidungen aus Sicht unterschiedlicher Produktionsumgebungen bestätigen, relativieren oder kontextabhängig einschränken lassen. Die Spalte *Evaluation* fasst hierzu die dominanten Deutungsmuster aus der Ergebnisanalyse zusammen, ohne einzelne Interviewaussagen erneut zu zitieren. Die verwendeten Kategorien der Rückspiegelung dienen der analytischen Verdichtung der Evaluationsergebnisse. *Bestätigt* bezeichnet eine hohe Über-

einstimmung zwischen Designannahmen und Praxiseinschätzungen. *Kontextabhängig* verweist auf Anforderungen, deren praktische Wirksamkeit von infrastrukturellen oder organisatorischen Rahmenbedingungen abhängt. *Relativiert* kennzeichnet Anforderungen, deren Relevanz oder Priorität aus Sicht der Experten eingeschränkt wird. *Potenziell bestätigt* beschreibt Anforderungen, die als fachlich richtig, jedoch noch nicht praxisreif eingeschätzt werden.

Tabelle 16: Rückspiegelung der Evaluation auf den systematischen Anforderungsabgleich

ID	Anforderung	Umsetzungsstand	Evaluation	Rückspiegelung
R1	Integration heterogener Datenquellen	erfüllt	Die Integration wird als zentraler Enabler bewertet, zugleich jedoch als in der Praxis stark von Anlagenalter, Schnittstellenstandardisierung und Datenqualität abhängig beschrieben.	kontextabhängig
R2	Digitale Erfassung von Domänenwissen	teilweise erfüllt	Die Experten sehen hohen Nutzen in der Externalisierung von Erfahrungswissen, betonen jedoch Aufwand, Pflegebedarf und Governance als Erfolgsfaktoren.	bestätigt
R3	Einheitliche zeitliche Referenzierung	erfüllt	Zeitliche Synchronisation wird als notwendige Grundvoraussetzung für belastbare Analysen angesehen; Herausforderungen ergeben sich vor allem bei heterogenen Quellen und fehlender Zeitstempelqualität.	bestätigt
R4	Konsistente Informationsintegration	erfüllt	Die Integrationslogik wird als sinnvoller Ordnungsrahmen wahrgenommen; in der Umsetzung wird die Abstimmung zwischen IT/OT und Domänenbereichen als kritischer Punkt hervorgehoben.	bestätigt
R5	Persistente Wissensbasis	teilweise erfüllt	Eine persistente Wissensbasis wird als strategisch relevant bewertet (Wissenserhalt, Lernfähigkeit). Akzeptanz und Aktualität hängen jedoch von Verantwortlichkeiten und Nutzungskonzepten ab.	kontextabhängig
R6	Explizite Problemdefinition und Metriken	erfüllt	Klare Problemdefinition und Metriken werden als Voraussetzung für Vertrauen und betriebliche Anschlussfähigkeit betont; ohne messbaren Nutzen sinkt die Bereitschaft zur Verstetigung.	bestätigt

Fortsetzung auf der nächsten Seite

ID	Anforderung	Umsetzungsstand	Evaluation	Rückspiegelung
R7	Versionierbares Merkmalsmanagement	teilweise erfüllt	Versionierung und Reproduzierbarkeit werden als wichtig für Skalierung und Nachvollziehbarkeit gesehen; in der Praxis wird der zusätzliche organisatorische Aufwand betont.	kontextabhängig
R8	Trennung Training und Betrieb	erfüllt	Die Trennung wird als realistisch und sinnvoll beschrieben; die Ausgestaltung (Edge vs. Cloud) wird als standort- und governanceabhängig bewertet.	bestätigt
R9	Produktiver Modellbetrieb	erfüllt	Produktiver Betrieb wird grundsätzlich als möglich eingeschätzt, jedoch abhängig von Betriebsverantwortung, Monitoring und Supportstrukturen.	kontextabhängig
R10	Modellüberwachung	teilweise erfüllt	Monitoring wird als akzeptanz- und vertrauensrelevant beschrieben; fehlende Drift-/Qualitätsüberwachung wird als Risiko für nachhaltige Nutzung hervorgehoben.	relativiert
R11	Adaptions- und Retrainingfähigkeit	vorbereitet	Retraining wird als notwendig für Robustheit und Skalierung angesehen, erfordert jedoch klare Prozesse, Daten-/Labelverfügbarkeit und zentrale Verantwortlichkeiten.	potenziell bestätigt
R12	Ergebnisvisualisierung	erfüllt	Verständliche Visualisierung wird als Schlüsselfaktor für Nutzung und Akzeptanz gesehen; adressatengerechte Aufbereitung wird als notwendige Ergänzung zu Modellgüte betont.	bestätigt
R13	Ableitung von Handlungsempfehlungen	vorbereitet	Handlungsempfehlungen werden als Zielbild anerkannt, zugleich wird betont, dass diese eine belastbare kausal-prädiktive Wissensbasis und erklärbare Logiken voraussetzen.	potenziell bestätigt
R14	Funktionale Trennung Wissensnutzung	teilweise erfüllt	Die Trennung wird als konzeptionell sinnvoll bewertet; praktisch hängt sie von Plattformfähigkeit, Rollenmodellen und Prozessintegration ab.	kontextabhängig

Die tabellarische Gegenüberstellung verdeutlicht mehrere übergreifende Muster. Ein erster Befund betrifft Anforderungen, die sowohl im Demonstrationskontext als auch in der Evaluation konsistent bestätigt werden (z. B. R3, R4, R6, R8, R12). Diese Anforderungen adressieren grundlegende Strukturprinzipien der Datenintegration, Analyse und Ergebnisaufbereitung und werden von den Experten als notwendige Basiselemente einer datengetriebenen Instandhaltungsarchitektur angesehen. Ihre Erfüllung erweist sich weitgehend unabhängig vom spezifischen Produktionskon-

text als Voraussetzung für Anschlussfähigkeit und Vertrauen in datenbasierte Systeme.

Ein zweites Muster zeigt sich bei Anforderungen, deren Erfüllung im Artefakt grundsätzlich angelegt ist, deren praktische Wirksamkeit jedoch stark kontextabhängig ausfällt (z. B. R1, R5, R7, R9, R14). Hier verweisen die Experten wiederholt auf infrastrukturelle Heterogenität, organisatorische Zuständigkeiten und den erforderlichen Pflegeaufwand als limitierende Faktoren. Diese Anforderungen markieren keine konzeptionellen Schwächen des Referenzmodells, sondern verdeutlichen vielmehr, dass ihre Realisierung einen bestimmten Reifegrad der Daten- und Organisationsstrukturen voraussetzt.

Besonders deutlich wird dies bei den Anforderungen R10 (Modellüberwachung), R11 (Adaptions- und Retrainingfähigkeit) und R13 (Ableitung von Handlungsempfehlungen), die in der Evaluation als fachlich notwendig, jedoch noch nicht vollständig praxisreif eingeordnet werden. Diese Anforderungen bilden ein zusammenhängendes Reifegrad-Cluster, das weniger durch isolierte technische Defizite gekennzeichnet ist, sondern vielmehr durch die Abhängigkeit von vorgelagerten Voraussetzungen wie stabilen Datenflüssen, belastbaren kausal-prädiktiven Modellen, erklärbaren Entscheidungslogiken sowie klaren organisatorischen Verantwortlichkeiten. Die Experteneinschätzungen legen nahe, dass diese Anforderungen nicht parallel zu grundlegenden Modellfunktionen umgesetzt werden sollten, sondern als aufbauende Entwicklungsstufe zu verstehen sind.

Aus der Evaluation lassen sich damit mehrere Designimplikationen ableiten. Erstens bestätigt sich die Entscheidung, das Referenzmodell modular und entwicklungsfähig auszulegen, da unterschiedliche Anforderungen zu unterschiedlichen Zeitpunkten und unter variierenden Rahmenbedingungen wirksam werden. Zweitens wird deutlich, dass eine konsequente Fokussierung auf kausal-prädiktive Analysen als Zwischenschritt methodisch sinnvoll ist, da diese eine belastbare Wissensbasis für weiterführende präskriptive Ansätze schaffen. Drittens unterstreicht die Evaluation die Notwendigkeit, Skalierbarkeit nicht allein technisch zu adressieren, sondern architektonisch und organisatorisch zu verankern, etwa durch zentrale Modellbereitstellung, Governance-Strukturen und standardisierte Betriebsprozesse.

Zusammenfassend zeigt die Rückspiegelung der Evaluation, dass das Referenzmodell die in **Kapitel 5.9** formulierten Anforderungen in weiten Teilen konsistent adressiert und dass die im Demonstrationskontext identifizierten Umsetzungsgrenzen durch die Einschätzungen der Experten aus unterschiedlichen Produktionsumgebungen weitgehend bestätigt werden. Die Gegenüberstellung von Anforderungsdefinition, Umsetzungsstand und Evaluation verdeutlicht zugleich, dass sich die Designanforderungen nicht als gleichrangig in ihrer praktischen Reife ausprägen, sondern unterschiedliche Reifegradstufen aufweisen. Insbesondere Anforderungen mit Bezug zu kontinuierlicher Modellüberwachung, Adaptions- und Retrainingfähigkeit sowie zur Ableitung präskriptiver Handlungsempfehlungen lassen sich nicht isoliert betrachten, sondern bauen auf einer stabilen kausal-prädiktiven Wissensbasis auf. Die Evaluation bestätigt damit, dass die im Rahmen der Fallstudien umgesetzten kausal-prädiktiven Analysen als notwendige Vorstufe für weiterführende präskriptive Ansätze zu verstehen sind und eine zentrale Grundlage für deren spätere Realisierung darstellen. Die identifizierten Kontextabhängigkeiten und Reifegradunterschiede sind dabei nicht als Schwächen des Artefakts zu interpretieren, sondern als Ausdruck eines realistischen, praxisnahen Entwicklungsansatzes, der die schrittweise Einführung, Übertragung und Skalierung datengetriebener Instandhaltungsstrategien ermöglicht. Insgesamt stützt die Evaluation die Positionierung des Referenzmodells als entwicklungsfähigen Bezugsrahmen, der sowohl aktuelle Anforderungen der prädiktiven Instandhaltung erfüllt als auch strukturell auf weiterführende präskriptive Ansätze vorbereitet ist. **Kapitel 7.3** schließt damit die Evaluation ab, indem die empirischen Ergebnisse systematisch auf die zugrunde liegenden Designentscheidungen zurückgeführt werden und eine belastbare Grundlage für die anschließende zusammenfassende Würdigung und den Ausblick geschaffen wird.

8 Zusammenfassung, kritische Würdigung und Ausblick

Der abschließende Teil dieser Arbeit dient der systematischen Reflexion und Einordnung der erzielten Forschungsergebnisse im Kontext des gewählten wissenschaftlichen Vorgehens nach dem Paradigma des DSR. In Übereinstimmung mit den Grundprinzipien dieses Forschungsansatzes umfasst der Abschluss eines DSR-Zyklus nicht nur die Darstellung eines entworfenen und evaluierten Artefakts, sondern auch die kritische Auseinandersetzung mit dessen wissenschaftlicher und praktischer Relevanz. Durch die Verknüpfung von Gestaltungs- und Erkenntnisbeitrag wird sichergestellt, dass die entwickelten Lösungen sowohl theoretisch fundiert als auch empirisch nachvollziehbar validiert sind. Der Abschluss ist damit nicht lediglich formaler Bestandteil des Forschungsprozesses, sondern wissenschaftlich erforderlich, um den Beitrag der Arbeit zur Wissensbasis der Disziplin transparent darzustellen.

Im Folgenden werden in **Kapitel 8.1** die zentralen Ergebnisse des Forschungsprozesses zusammengefasst und in den Kontext der übergeordneten Forschungsfragen eingeordnet. Dabei wird aufgezeigt, inwiefern die formulierten Zielsetzungen erreicht und die entwickelten Artefakte durch Demonstration und Evaluation gestützt werden konnten. Darauf aufbauend widmet sich **Kapitel 8.2** der kritischen Würdigung der Arbeit. Neben der Reflexion methodischer und inhaltlicher Grenzen werden offene Forschungsfragen und weiterführende Perspektiven skizziert, die sich aus den gewonnenen Erkenntnissen ableiten lassen.

8.1 Zusammenfassung der Forschungsergebnisse

Der in dieser Arbeit verfolgte Forschungsprozess orientierte sich stringent am methodischen Rahmen des DSR. Ziel war es, durch Gestaltung, Implementierung und Evaluation eines anwendungsorientierten Artefakts einen wissenschaftlich fundierten und zugleich praxisrelevanten Beitrag zur datengetriebenen Instandhaltung in industriellen Produktionsumgebungen zu leisten. Im Zentrum stand die Entwicklung eines Referenzmodells einer intelligenten Data Pipeline, das sich in bestehende IT-Infrastrukturen integrieren lässt und einen kausal-prädiktiven Instandhaltungsansatz als Grundlage für weiterführende präskriptive Instandhaltungsstrategien strukturiert unterstützt. Der DSR-Ansatz ermöglichte dabei die systematische Verbindung von theoretischer Konzeptentwicklung, technischer Demonstration und empirischer Evaluation, wodurch ein geschlossener Forschungszyklus im Sinne eines iterativen Gestaltungsprozesses realisiert werden konnte.

Ausgangspunkt bildete die Identifikation einer Forschungslücke im Spannungsfeld zwischen datenbasierter Instandhaltung und daten- bzw. informationsintegrierten Produktionsumgebungen. Trotz zahlreicher Ansätze zur Anwendung von Data-Mining- und KI-Methoden in der Industrie fehlte bislang ein übergreifender, referenzmodellbasierter Ordnungsrahmen, der die durchgängige Verknüpfung von Datenakquise, Informationsintegration, Analyse, Modellierung und Ergebnisinterpretation über mehrere Ebenen des Produktionssystems hinweg strukturiert. Diese Lücke wurde durch die Entwicklung einer intelligenten Data Pipeline adressiert, deren Referenzmodell eine integrierte Grundlage für kausal-prädiktive Analysen schafft und damit die Wissensbasis für präskriptive Entscheidungsunterstützung vorbereitet.

Die Arbeit folgte einem mehrstufigen Forschungsdesign. Auf konzeptioneller Ebene wurde zunächst das Referenzmodell der intelligenten Data Pipeline entwickelt und theoretisch im Kontext der Produktionsdomäne verortet. Das Modell umfasst funktionale Ebenen der Datenakquise, Vorverarbeitung und Bereitstellung, Informationsintegration, Analyse, Überwachung, Entscheidungsunterstützung sowie Modellierung. Es bildet einen modularen und technologisch offenen Rahmen für eine durchgängige Dateninfrastruktur, die eine automatisierte Verarbeitung und Kontextualisierung industrieller Prozessdaten ermöglicht.

Auf der **Makroebene** erfolgte anschließend die konzeptionelle und teilweise technische Integration des Referenzmodells in die bestehende IT- und Produktionsinfrastruktur eines Automobilpress-

werks. Dabei konnte gezeigt werden, dass die konzipierte Architektur grundsätzlich realisierbar ist, sofern organisatorische und semantische Voraussetzungen wie standardisierte Schnittstellenstrukturen, definierte Zugriffskonzepte sowie die Einbindung domänenspezifischer Expertise gegeben sind. Eine vollständige Umsetzung des Referenzmodells war im Rahmen der praktischen Demonstration jedoch nicht in allen Bestandteilen möglich, da insbesondere die automatisierte Anbindung und Strukturierung bestehenden Domänenwissens aufgrund fehlender Schnittstellen und heterogener Dokumentationspraktiken nur eingeschränkt realisiert werden konnte. Diese Einschränkung verweist auf eine weiterhin bestehende Diskrepanz zwischen konzeptioneller Daten- und Wissensintegration und realen Systemlandschaften industrieller Produktionsumgebungen. Zugleich lieferten die Demonstrationsarbeiten belastbare Erkenntnisse über technische und organisatorische Integrationshürden, insbesondere hinsichtlich IT-Sicherheitszonierung, heterogener Datenquellen und dezentraler Wissensdokumentation.

Auf der **Mikroebene** wurde die Leistungs- und Anpassungsfähigkeit der intelligenten Data Pipeline anhand dreier exemplarischer Fallstudien überprüft, die unterschiedliche Datenkontexte und Produktionsdomänen abbilden. In der **Ziehkissen-Fallstudie** stand die Analyse realer Prozessdaten eines Umformprozesses im Vordergrund. Durch die Integration von Datenaufnahme, Vorverarbeitung, Analyse und Ergebnisinterpretation konnte die Datendurchgängigkeit der Pipeline demonstriert werden. Zudem zeigte sich, dass datengetriebene Modelle charakteristische Muster und Anomalien im Prozessverhalten erkennen können und damit eine Grundlage für kausal-prädiktive Zustandsbewertung und Überwachungsstrategien bilden. Die **Zahnstangenantriebs-Fallstudie** diente der modellbasierten Untersuchung von Verschleißzuständen auf einem Transfersimulator. Durch die Kombination aus simulativer Datengenerierung und datengetriebener Modellierung wurde die Übertragbarkeit der Methodik auf virtuelle Produktionsumgebungen demonstriert. Zugleich zeigte sich, dass simulierte Daten eine wertvolle Ergänzung darstellen können, um Modellgüte und Robustheit systematisch zu prüfen. Die **Druckluftgreifer-Fallstudie** bildete den explorativen Abschluss der Data-Mining-Anwendungen. Ziel war es, datengetriebene Verfahren in einer realen, durch hohe Prozessdynamik und variierende Randbedingungen geprägten Umgebung zu erproben. Anhand unüberwachter Lernverfahren und statistischer Methoden konnten charakteristische Abweichungen in Verbrauchszyklen identifiziert und plausibel mit beobachteten Störungen korreliert werden, sodass auch ohne vollständige Annotation nutzbare Indikatoren für sich anbahnende Störungen abgeleitet werden konnten.

Die drei Fallstudien belegen insgesamt die Funktionalität und Anpassungsfähigkeit der intelligenten Data Pipeline als Rahmen für die Integration, Verarbeitung und Analyse industrieller Prozessdaten. Aussagen zur standortübergreifenden Skalierung werden dabei nicht als Ergebnis eines Rollouts verstanden, sondern als architektonisch angelegte Eigenschaft, deren praktische Realisierung von Standardisierung, Governance und Kontextbedingungen abhängt.

Zur abschließenden Evaluation der im Rahmen des DSR entwickelten Artefakte wurde ein qualitativ-empirisches Untersuchungsdesign in Form semistrukturierter Experteninterviews gewählt. Ziel war es, Nützlichkeit, Verständlichkeit, Anwendbarkeit, Übertragbarkeit und Akzeptanz des Referenzmodells sowie der exemplarischen Data-Mining-Anwendungen zu bewerten. Insgesamt wurden **19 Interviews** durchgeführt. In einer ersten Erhebungswelle wurden Fach- und Führungskräfte innerhalb eines Produktionsstandorts befragt, um eine artefaktnahe Bewertung unter vergleichbaren Rahmenbedingungen zu ermöglichen. Darauf folgend wurde in einer zweiten Erhebungswelle die Stichprobe gezielt um Experten aus weiteren nationalen und internationalen Produktionsumgebungen erweitert, um zusätzliche Perspektiven zu Übertragbarkeit und Skalierbarkeit zu erfassen. Die Auswahl erfolgte nach dem Prinzip des *theoretical sampling*. Die Interviews wurden vollständig transkribiert, ausgewertet und entlang der Evaluationsdimensionen verdichtet. Die Ergebnisse bestätigen die Relevanz des Referenzmodells insbesondere im Hinblick auf die strukturierte Modularisierung und die Unterstützung kausal-prädiktiver Analysen, weisen jedoch

zugleich auf kontextabhängige Voraussetzungen und Weiterentwicklungsbedarfe hin, insbesondere bezüglich Wissensintegration, organisatorischer Verankerung und der Anschlussfähigkeit für präskriptive Entscheidungslogiken.

Auf der **Mikroebene** wurde die Leistungs- sowie Anpassungsfähigkeit der intelligenten Data Pipeline anhand von drei exemplarischen Fallstudien überprüft, die unterschiedliche Produktionsdomänen und Datenkontexte abbilden. In der **Ziehkissen-Fallstudie** stand die Analyse realer Prozessdaten eines Umformprozesses im Vordergrund. Durch die vollständige Integration der Datenaufnahme, Vorverarbeitung, Analyse und Ergebnisinterpretation konnte die Datendurchgängigkeit der intelligenten Data Pipeline technisch nachgewiesen werden. Zudem zeigte sich, dass datengetriebene Modelle in der Lage sind, charakteristische Muster und Anomalien im Prozessverhalten zu erkennen und so eine Grundlage für zustandsbasierte Überwachungsstrategien zu bilden. Damit wurde die prinzipielle Eignung der Pipeline zur industriellen Prozessanalyse empirisch bestätigt. Die **Zahnstangenantriebs-Fallstudie** diente der modellbasierten Untersuchung von Verschleißzuständen auf einem Transfer-Simulator. Durch die Kombination aus simulativer Datengenerierung und datengetriebener Modellierung konnte die Übertragbarkeit der entwickelten Methodik auf virtuelle Produktionsumgebungen demonstriert werden. Der Einsatz von neuronalen Netzen ermöglichte die präzise Klassifikation von Systemzuständen sowie die Identifikation potenzieller Abweichungen. Die Fallstudie verdeutlichte darüber hinaus, dass simulierte Prozessdaten eine wertvolle Ergänzung zur realen Datengrundlage darstellen können, um Modellgüte und Robustheit systematisch zu überprüfen. Die **Druckluftgreifer-Fallstudie** bildete den explorativen Abschluss der Data-Mining-Anwendungen. Ziel war es, datengetriebene Lernverfahren in einer realen, durch hohe Prozessdynamik und variierende Randbedingungen geprägten Produktionsumgebung zu erproben. Im Mittelpunkt stand dabei die Analyse von Luftverbrauchssignalen, um Muster und Anomalien zu identifizieren, die auf potenzielle Fehlfunktionen oder ineffiziente Zustände im pneumatischen System hinweisen. Anhand unüberwachter Lernverfahren und statistischer Methoden konnten charakteristische Abweichungen in den Verbrauchszyklen erkannt und plausibel mit beobachteten Störungen korreliert werden. Die Ergebnisse verdeutlichten, dass datengetriebene Modelle auch ohne explizite Zielgrößen oder vollständige Prozessannotierung wertvolle Indikatoren für sich anbahnende Störungen liefern können. Die drei Fallstudien belegen insgesamt die Funktionalität, Flexibilität und Skalierbarkeit der intelligenten Data Pipeline. Sowohl im Kontext realer Produktionssysteme als auch in simulationsbasierten Szenarien konnte gezeigt werden, dass die konzipierte Architektur einen robusten Rahmen für die Integration, Verarbeitung und Analyse industrieller Prozessdaten bereitstellt.

Leitforschungsfrage:

Wie ist ein Referenzmodell einer intelligenten Data Pipeline für Produktionsumgebungen zu gestaltet, das sich in bestehende IT-Infrastrukturen integrieren lässt und einen kausal-prädiktiven Instandhaltungsansatz als Grundlage für eine präskriptive Instandhaltungsstrategie strukturiert unterstützt?

Die Leitforschungsfrage zielte auf die Entwicklung und Validierung eines Referenzmodells, das eine strukturierte und integrierbare Grundlage für datengetriebene Instandhaltungsprozesse in industriellen Produktionsumgebungen bereitstellt und zugleich einen kausal-prädiktiven Instandhaltungsansatz als Voraussetzung für weiterführende präskriptive Strategien unterstützt. Im Sinne des DSR stand dabei die Gestaltung eines Artefakts im Mittelpunkt, das sowohl technisch anschlussfähig an bestehende IT-Infrastrukturen als auch wissenschaftlich fundiert ist und damit einen doppelten Erkenntnisbeitrag leistet. Die Beantwortung der Leitforschungsfrage erfolgte durch die konzeptionelle Entwicklung, exemplarische Demonstration und empirische Evaluation der intelligenten Data Pipeline, die in dieser Arbeit als zentrales Artefakt entworfen wurde. Das entwickelte

Referenzmodell beschreibt eine mehrschichtige Architektur, welche die Ebenen der Datenakquise, Vorverarbeitung und Bereitstellung, Informationsintegration, Analyse, Überwachung, Entscheidungsunterstützung sowie Modellierung systematisch miteinander verknüpft. Dadurch wird die vollständige Prozesskette von der Rohdatenerfassung bis zur Ableitung kontextualisierter Handlungsempfehlungen strukturiert abgebildet. Im Unterschied zu isolierten Analyseansätzen liegt der Schwerpunkt des Modells auf der durchgängigen Integration von Daten-, Wissens- und Analyseebene, wodurch kausal begründete prädiktive Aussagen möglich werden, die als notwendige Wissensbasis für präskriptive Entscheidungslogiken dienen.

Eine zentrale Grundlage für die Modellgestaltung bildete die in **Kapitel 5.9** entwickelte Anforderungsmatrix, in der technische, organisatorische und methodische Anforderungen an ein Referenzmodell für datengetriebene Instandhaltungsstrategien systematisch zusammengeführt wurden. Diese Anforderungen wurden in Gestaltungsprinzipien wie Modularität, technologische Offenheit, funktionale Entkopplung und Interoperabilität überführt und bildeten den normativen Rahmen für die Ausgestaltung der intelligenten Data Pipeline. Die modulare Struktur des Referenzmodells ermöglicht es, einzelne Funktionsschichten unabhängig weiterzuentwickeln und zugleich über klar definierte Schnittstellen zu integrieren. Damit wird sowohl die Einbindung heterogener Datenquellen als auch die Ankopplung externer Analyse- und Wissenssysteme unterstützt.

Die Demonstration des Referenzmodells erfolgte in zwei komplementären Schritten. Auf **architektonischer Ebene** konnte durch die exemplarische Integration in die bestehende IT- und Produktionsinfrastruktur eines Automobilpresswerks gezeigt werden, dass das Modell grundsätzlich mit realen, sicherheitszonierten und heterogenen Systemlandschaften vereinbar ist. Dabei wurden zugleich strukturelle Grenzen identifiziert, insbesondere im Hinblick auf proprietäre Schnittstellen, fragmentierte Datenhaltung und die eingeschränkte maschinelle Nutzbarkeit von Domänenwissen. Diese Erkenntnisse verdeutlichen, dass die Integration einer intelligenten Data Pipeline weniger an fehlenden Analyseverfahren scheitert als vielmehr an der fehlenden Standardisierung und semantischen Erschließung bestehender Informationsquellen. Auf **operativer Ebene** wurde die Leistungsfähigkeit der Pipeline anhand mehrerer Fallstudien überprüft, in denen reale und simulierte Produktionsdaten analysiert wurden. Die Ergebnisse zeigen, dass die entwickelte Architektur geeignet ist, kausal-prädiktive Modelle zu unterstützen, indem datengetriebene Muster mit Prozess- und Domänenkontext verknüpft werden. Insbesondere die Fallstudien verdeutlichen, dass prädiktive Analysen, die auf physikalisch und prozessual plausiblen Merkmalen aufbauen, eine belastbare Grundlage für spätere präskriptive Ansätze darstellen. Damit wird der Übergang von reiner Mustererkennung hin zu wissensgestützter Entscheidungsunterstützung strukturell vorbereitet, ohne eine vollständige Präskriptivität vorwegzunehmen.

Die ergänzende Evaluation durch Experteninterviews bestätigt diese Einordnung. Die Befragten bewerteten das Referenzmodell als verständlich, anschlussfähig und grundsätzlich übertragbar, betonten jedoch zugleich, dass die Umsetzung datengetriebener Instandhaltungsstrategien nicht allein eine technische, sondern vor allem eine organisatorische und semantische Herausforderung darstellt. Insbesondere die systematische Integration von Domänenwissen, die Nachvollziehbarkeit analytischer Ergebnisse sowie die organisatorische Verankerung datengetriebener Entscheidungsprozesse wurden als zentrale Voraussetzungen identifiziert. Die Interviews stützen damit die Positionierung des Referenzmodells als entwicklungsfähigen Bezugsrahmen, der kausal-prädiktive Analysen konsistent unterstützt und zugleich strukturell auf präskriptive Erweiterungen vorbereitet ist.

Zusammenfassend beantwortet diese Arbeit die Leitforschungsfrage dahingehend, dass das entwickelte Referenzmodell einer intelligenten Data Pipeline gezielt darauf ausgelegt ist, kausal-prädiktive Instandhaltungsanalysen systematisch zu ermöglichen und damit die notwendige Wissensbasis für weiterführende präskriptive Instandhaltungsstrategien zu schaffen. Das Referenzmodell operationalisiert diese Zielsetzung, indem es die funktionalen Ebenen des Referenzmodells in

einer konsistenten Architektur verknüpft und damit den Übergang von datengetriebener Musterkennung hin zu kausal begründeter Zustandsbewertung strukturell unterstützt.

Im Kern positioniert sich das Referenzmodell nicht als vollständig präskriptives System, sondern als methodisch und architektonisch vorbereitender Bezugsrahmen, der prädiktive Analysen explizit in einen wissensbasierten Kontext einbettet. Durch die Integration einer persistenten Wissensbasis, die Kopplung analytischer Ergebnisse an domänenspezifische Informationen sowie die funktionale Trennung von Modellbildung, -betrieb und -nutzung wird sichergestellt, dass prädiktive Ergebnisse erklärbar, nachvollziehbar und anschlussfähig für regel- oder wissensbasierte Handlungsempfehlungen sind. Damit adressiert das Referenzmodell bewusst die zentrale Voraussetzung präskriptiver Instandhaltung und damit nicht die bloße Vorhersage, sondern die kausal fundierte Ableitung handlungsrelevanter Informationen.

Die Ergebnisse aus Demonstration und Evaluation zeigen, dass das Referenzmodell insbesondere in komplexen Produktionsumgebungen eine tragfähige Struktur bereitstellt, um heterogene Datenquellen, analytische Verfahren und Domänenwissen systematisch zu integrieren. Die Fallstudien belegen, dass kausal-prädiktive Analysen innerhalb der Modelllogik konsistent umgesetzt werden können, während die Experteninterviews bestätigen, dass genau diese Struktur als notwendige Grundlage für eine schrittweise Weiterentwicklung in Richtung präskriptiver Entscheidungsunterstützung wahrgenommen wird. Präskriptive Funktionalitäten werden dabei nicht als isoliertes Ziel verstanden, sondern als konsequente Weiterentwicklung auf Basis der im Referenzmodell angelegten Wissens- und Analysearchitektur.

Damit zeigt die Arbeit, dass das entwickelte Referenzmodell eine belastbare Antwort auf die Leitforschungsfrage liefert. Es ermöglicht eine integrierbare, kausal-prädiktive Instandhaltung in bestehenden IT-Infrastrukturen und schafft zugleich die strukturellen Voraussetzungen, um präskriptive Instandhaltungsstrategien methodisch fundiert und kontextsensitiv weiterzuentwickeln.

Forschungsfrage 1:

Welche Herausforderungen ergeben sich bei der Integration eines Referenzmodells einer intelligenten Data Pipeline für datengetriebene Instandhaltungsstrategien in die bestehende IT-Infrastruktur einer Produktionsumgebung?

Die Beantwortung der ersten Forschungsfrage zeigt, dass sich die Integration eines Referenzmodells einer intelligenten Data Pipeline in bestehende industrielle IT-Infrastrukturen als vielschichtiges Gestaltungsproblem erweist, das im Rahmen des DSR insbesondere im Relevanz- und Designzyklus sichtbar wurde. Die im Zuge der Demonstration und Evaluation gewonnenen Erkenntnisse verdeutlichen, dass die Herausforderungen weniger in der grundsätzlichen technischen Machbarkeit liegen, sondern primär in der Einbettung des Referenzmodells in historisch gewachsene, heterogene und sicherheitskritische Systemlandschaften.

Auf technischer Ebene wurde deutlich, dass bestehende Produktionsumgebungen durch eine ausgeprägte Fragmentierung der IT-Landschaft gekennzeichnet sind. Produktions- und Informationsebenen sind häufig durch proprietäre Schnittstellen, unterschiedliche Datenformate und restriktive Sicherheitszonierungen voneinander getrennt. Die exemplarische Integration des Referenzmodells in ein Automobilpresswerk zeigte, dass insbesondere IT-Sicherheitsrichtlinien und Zonierungskonzepte die bidirektionale Datenkommunikation zwischen Maschinenebene, Analyseumgebung und Wissenschicht erheblich einschränken. Zwar konnten relevante Prozess- und Maschinendaten technisch erschlossen werden, der Zugriff erfolgte jedoch teilweise nur indirekt oder verzögert, was zusätzliche Konvertierungs- und Schnittstellenprozesse erforderlich machte. Diese Befunde unterstreichen, dass die Integration einer intelligenten Data Pipeline nicht isoliert als Analyseproblem verstanden werden kann, sondern eine explizite architektonische Berücksichtigung

bestehender IT-Governance-Strukturen erfordert. Das entwickelte Referenzmodell adressiert diese Herausforderung, indem es eine klare funktionale Trennung der Verarbeitungsebenen vorsieht und Integrationspunkte definiert, ohne eine vollständige Durchdringung bestehender Systeme zu erzwingen.

Neben der technischen Heterogenität erwies sich die semantische Integration als zentrale Herausforderung im Designzyklus. Zwar konnten Sensordaten, Steuerungsinformationen und zeitbasierte Prozessdaten erfolgreich verarbeitet werden, jedoch fehlten in der bestehenden Systemlandschaft standardisierte Strukturen zur Verknüpfung dieser Daten mit domänenspezifischem Wissen, etwa aus Wartungshistorien, Anlagenbüchern oder technischen Dokumentationen. Diese Lücke erschwerte eine kontextualisierte Interpretation analytischer Ergebnisse und limitierte die unmittelbare Ableitung präskriptiver Handlungsempfehlungen. Die Arbeit zeigt damit, dass die Integration eines Referenzmodells nicht allein durch Datenzugänglichkeit bestimmt wird, sondern maßgeblich von der Fähigkeit abhängt, Daten und Wissen systematisch zu koppeln. Das Referenzmodell der intelligenten Data Pipeline trägt dieser Erkenntnis Rechnung, indem es eine dedizierte Wissensschicht vorsieht, die als Bindeglied zwischen datengetriebener Analyse und domänenspezifischer Interpretation fungiert. Die praktische Umsetzung verdeutlichte jedoch, dass diese Schicht in realen Produktionsumgebungen nur dann wirksam werden kann, wenn entsprechende semantische Grundlagen und organisatorische Prozesse etabliert sind.

Im Relevanzzyklus traten darüber hinaus organisatorische und kulturelle Herausforderungen deutlich hervor. Die Integration des Referenzmodells berührte bestehende Zuständigkeitsgrenzen zwischen IT, Instandhaltung und Produktion und machte unklare Verantwortlichkeiten für Datenhoheit, Systembetrieb und Modellpflege sichtbar. Gleichzeitig zeigte sich, dass datengetriebene Instandhaltungsansätze in vielen Organisationen noch nicht als strategisches Element verankert sind, sondern häufig projekt- oder personengetrieben verfolgt werden. Die Akzeptanz automatisierter Analyseverfahren wurde von den befragten Experten als kritischer Erfolgsfaktor benannt, insbesondere im Hinblick auf die Transparenz von Modellentscheidungen und den Aufbau datenanalytischer Kompetenzen. Diese Befunde verdeutlichen, dass die Integration eines Referenzmodells nicht allein durch technische Architekturentscheidungen gelöst werden kann, sondern eine organisatorische Einbettung erfordert, die Rollen, Verantwortlichkeiten und Kompetenzaufbau explizit berücksichtigt.

Im Strengezyklus zeigte sich schließlich, dass die bestehende wissenschaftliche Literatur zur industriellen Datenintegration zwar umfangreiche konzeptionelle Modelle bereitstellt, konkrete Umsetzungsstrategien für heterogene, sicherheitszonierte Produktionsumgebungen jedoch bislang nur begrenzt empirisch abgesichert sind. Die in dieser Arbeit gewonnenen Erkenntnisse leisten daher einen Beitrag zur Schließung dieser Lücke, indem sie zeigen, unter welchen realen Rahmenbedingungen ein Referenzmodell einer intelligenten Data Pipeline anschlussfähig ist und wo konzeptionelle Annahmen an praktische Grenzen stoßen.

Zusammenfassend lässt sich festhalten, dass die Integration eines Referenzmodells einer intelligenten Data Pipeline nur dann erfolgreich gelingt, wenn technische, semantische und organisatorische Aspekte als miteinander verflochtene Dimensionen eines sozio-technischen Gesamtsystems gestaltet werden. Die identifizierten Herausforderungen sind dabei nicht als Defizite des entwickelten Referenzmodells zu verstehen, sondern als kontextabhängige Randbedingungen, die dessen praktische Umsetzung prägen. Gleichzeitig liefern sie zentrale Gestaltungsimplicationen für die Weiterentwicklung datengetriebener Instandhaltungsarchitekturen und bestätigen die Notwendigkeit eines modularen, interoperablen und wissensorientierten Referenzmodells, wie es in dieser Arbeit entwickelt wurde.

Forschungsfrage 2:

Welche Herausforderungen bestehen bei der Anwendung von Data-Mining-Methoden auf Produktions- und Maschinendaten im Hinblick auf die Gewinnung nutzbarer Informationen für datengetriebene Instandhaltungsstrategien?

Die Beantwortung der zweiten Forschungsfrage zeigt, dass die Anwendung von Data-Mining-Methoden auf Produktions- und Maschinendaten zwar ein hohes Potenzial für datengetriebene Instandhaltungsstrategien besitzt, zugleich jedoch mit einer Reihe struktureller und methodischer Herausforderungen verbunden ist. Im Rahmen des DSR wurden diese Herausforderungen über alle drei Zyklen hinweg sichtbar und verdeutlichen, dass die Gewinnung nutzbarer Informationen nicht allein von der Leistungsfähigkeit einzelner Algorithmen abhängt, sondern maßgeblich von deren Einbettung in einen konsistenten Daten-, Wissens- und Systemkontext.

Im Relevanzzyklus ergaben sich zentrale Herausforderungen aus den charakteristischen Eigenschaften industrieller Produktionsdaten. Diese sind häufig durch hohe Abstrakten, stark variierende Signalverläufe, zeitabhängige Korrelationen sowie eine nur unvollständige oder fehlende Annotation gekennzeichnet. Gleichzeitig enthalten sie Störsignale, Prozessrauschen und kontextabhängige Überlagerungen, die eine eindeutige Zuordnung von Datenmustern zu physikalischen Zuständen erschweren. Im Gegensatz zu kontrollierten Labor- oder Benchmark-Datensätzen sind industrielle Daten daher selten homogen oder vollständig beschrieben, was die direkte Anwendung etablierter Data-Mining-Verfahren limitiert und einen erheblichen Aufwand in der Datenaufbereitung, Synchronisation und Merkmalsextraktion erforderlich macht. Diese Befunde verdeutlichen, dass nutzbare Informationen nicht unmittelbar aus den Rohdaten ableitbar sind, sondern erst durch eine kontextsensitive Vorverarbeitung und Strukturierung entstehen.

Im Designzyklus zeigte sich, dass die Qualität der Informationsgewinnung wesentlich von der Wahl geeigneter Merkmale und Modellierungsansätze abhängt. Die Fallstudien verdeutlichen, dass unterschiedliche Prozesse jeweils spezifische Merkmalsräume erfordern. Während in der Ziehkissen-Fallstudie statistische und frequenzbasierte Merkmale besonders aussagekräftig für die Zustandsbewertung waren, erwiesen sich beim Zahnstangenantrieb sequenzielle Merkmale in Kombination mit neuronalen Netzen als geeignet, um zeitabhängige Verschleißzustände abzubilden. In der Druckluftgreifer-Fallstudie konnte wiederum gezeigt werden, dass unüberwachte Verfahren auch unter stark variierenden Randbedingungen in der Lage sind, charakteristische Abweichungen und Anomalien zu identifizieren, selbst wenn keine expliziten Zielgrößen oder vollständig annotierten Trainingsdaten vorliegen. Diese Ergebnisse unterstreichen, dass Feature Engineering und Modellauswahl zentrale Gestaltungsentscheidungen darstellen und nicht losgelöst vom jeweiligen Prozess- und Anlagenkontext getroffen werden können.

Eine wesentliche Herausforderung im Hinblick auf die Gewinnung nutzbarer Informationen betrifft die Interpretierbarkeit der eingesetzten Modelle. Zwar erzielten komplexe Modelle, insbesondere neuronale Netze, in mehreren Fallstudien eine hohe Klassifikations- oder Erkennungsleistung, die zugrunde liegende Entscheidungslogik blieb jedoch nur eingeschränkt nachvollziehbar. Für den industriellen Instandhaltungskontext stellt diese eingeschränkte Transparenz ein zentrales Hindernis dar, da Entscheidungen über Wartungsmaßnahmen, Eingriffe oder Stillstände erklärbar und begründbar sein müssen. Die Arbeit zeigte, dass die Interpretierbarkeit datengetriebener Ergebnisse in erheblichem Maße von der Verfügbarkeit und Einbindung domänenspezifischen Wissens abhängt. In mehreren Phasen des Vorhabens konnte dieses Wissen nur eingeschränkt durch direkten Austausch mit Fachexperten eingebunden werden, sodass technische Dokumentationen, Wartungsberichte und Erfahrungswerte manuell herangezogen und interpretiert werden mussten. Diese Beobachtungen verdeutlichen, dass die Qualität der Informationsgewinnung nicht allein eine algorithmische, sondern auch eine wissensbasierte Herausforderung darstellt.

Im Zuge der Analyse wurde deutlich, dass die Rückkopplung datengetriebener Muster mit

Expertenwissen einen entscheidenden Beitrag zur Validierung und Plausibilisierung der Ergebnisse leistet. Durch den Einsatz von Konfusionsmatrizen, Sensitivitätsanalysen und qualitativen Experteninterpretationen konnte eine Verbindung zwischen statistischen Modellergebnissen und domänenspezifischer Erfahrung hergestellt werden. Dieser iterative Abgleich entspricht einem zentralen Prinzip des Designzyklus, in dem analytische Artefakte schrittweise verfeinert und an den Anwendungskontext angepasst werden. Die Ergebnisse zeigen, dass die Einbindung von Domänenwissen nicht nur die Interpretierbarkeit, sondern auch die Robustheit und Generalisierbarkeit der Modelle signifikant erhöht und damit eine Voraussetzung für kausal-prädiktive Aussagen darstellt.

Ein weiterer zentraler Befund betrifft die eingeschränkte Übertragbarkeit von Modellen über unterschiedliche Anlagen und Prozesse hinweg. Modelle, die in einem spezifischen Anwendungskontext valide Ergebnisse lieferten, konnten nicht ohne Anpassung auf andere Prozesse übertragen werden. Diese Einschränkung resultiert sowohl aus der Heterogenität der Datentypen und Signalcharakteristika als auch aus den zugrunde liegenden physikalischen und steuerungstechnischen Prozessunterschieden. Zusätzlich erschwerten proprietäre Datenformate und fehlende Standards die Interoperabilität zwischen Analyseumgebungen und behinderten die Entwicklung wiederverwendbarer Auswertungsroutinen. Die Fallstudien verdeutlichten damit, dass Datenheterogenität im industriellen Umfeld nicht nur ein technisches, sondern auch ein erkenntnisorientiertes Problem darstellt. Ohne ein tiefes Verständnis der Prozesse und Einflussfaktoren besteht die Gefahr, dass erkannte Muster zwar statistisch signifikant, aber fachlich falsch interpretiert werden.

Im Strengeszyklus wurde darüber hinaus deutlich, dass viele in der Literatur etablierte Data-Mining-Verfahren nur eingeschränkt für den produktiven Einsatz unter Echtzeit- und Stabilitätsanforderungen geeignet sind. Der praktische Nutzen hängt daher weniger von der maximal erreichbaren Modellgüte ab als vielmehr von der Fähigkeit, Modelle zuverlässig, wartbar und systemverträglich in produktionsnahe IT-Umgebungen zu integrieren. Damit verschiebt sich der Fokus von der isolierten Optimierung einzelner Modelle hin zur ganzheitlichen Betrachtung der Informationsgewinnung unter realen Systemrestriktionen.

Zusammenfassend zeigt die Beantwortung der Forschungsfrage, dass die Anwendung von Data-Mining-Methoden auf Produktions- und Maschinendaten durch unvollständige Datenstrukturen, fehlende Standardisierung, hohe Interpretierbarkeitsanforderungen und Echtzeitrestriktionen geprägt ist. Die in dieser Arbeit entwickelten Vorgehensweisen und das zugrunde liegende Referenzmodell der intelligenten Data Pipeline adressieren diese Herausforderungen, indem sie Data-Mining nicht als isolierten Analyseprozess, sondern als Bestandteil einer integrierten, wissensbasierten Architektur verstehen. Dadurch wird die Gewinnung kausal-prädiktiver Informationen ermöglicht, die als belastbare Grundlage für datengetriebene und perspektivisch präskriptive Instandhaltungsstrategien dienen können.

Forschungsfrage 3:

Welche Anforderungen lassen sich an Konzepte ableiten, die Wissen aus technischen Anlagendokumentationen automatisiert mit Sensordaten verknüpfen, um kausal begründete Handlungsempfehlungen abzuleiten?

Die Beantwortung der dritten Forschungsfrage verdeutlicht, dass die automatisierte Verknüpfung von Wissen aus technischen Anlagendokumentationen mit Sensordaten eine zentrale Voraussetzung für kausal begründete Handlungsempfehlungen in datengetriebenen Instandhaltungsstrategien darstellt. Die Analyse zeigt zugleich, dass diese Verknüpfung im industriellen Kontext bislang nur unzureichend systematisiert ist und sowohl technische als auch wissensbezogene und organisationale Herausforderungen umfasst.

Im Relevanzzyklus des DSR wurde deutlich, dass relevantes Anlagen- und Prozesswissen in industriellen Produktionsumgebungen überwiegend in unstrukturierten oder semistrukturierten

Formaten vorliegt. Technische Dokumentationen wie Anlagenbücher, Wartungsprotokolle, Inbetriebnahmeanweisungen oder Störmeldungen sind in der Regel textuell abgefasst, historisch gewachsen und nicht eindeutig mit konkreten Sensoren, Komponenten oder Prozesszuständen verknüpft. Diese Form der Wissensrepräsentation verhindert eine direkte maschinelle Verarbeitung und erschwert insbesondere die automatisierte Kontextualisierung datengetriebener Analyseergebnisse. Gleichzeitig wurde deutlich, dass gerade diese Dokumentationen eine wesentliche Quelle für kausale Zusammenhänge darstellen, da sie Informationen über Funktionsprinzipien, bekannte Fehlerbilder, Wartungslogiken und betriebliche Erfahrungswerte enthalten, die für die Interpretation statistischer Muster unverzichtbar sind.

Im Designzyklus zeigte sich, dass eine automatisierte Verknüpfung von Dokumentationswissen und Sensordaten nur auf der Basis standardisierter und semantisch expliziter Wissensstrukturen realisierbar ist. Zentrale Anforderung ist hierbei eine formale Wissensrepräsentation, die technische Entitäten, funktionale Zusammenhänge und betriebliche Zustände eindeutig beschreibt und über Systemgrenzen hinweg referenzierbar macht. Ontologie-basierte Ansätze und Wissensgraphen erweisen sich in diesem Zusammenhang als besonders geeignet, da sie die Transformation unstrukturierter textueller Informationen in maschinenlesbare Wissensseinheiten ermöglichen und zugleich relationale Abhängigkeiten zwischen Komponenten, Prozessen und Zuständen explizit modellieren. Erst durch eine solche semantische Formalisierung kann Dokumentationswissen systematisch mit Sensordaten verknüpft und in analytische Prozesse eingebunden werden.

Eine weitere zentrale Anforderung betrifft die semantische Anreicherung der Sensordaten selbst. Messwerte müssen eindeutig Anlagenobjekten, Funktionsgruppen und Betriebszuständen zugeordnet werden können, um eine konsistente Verbindung zwischen Daten- und Wissensebene herzustellen. Die Arbeit zeigte, dass ohne eine solche Kontextualisierung datengetriebene Modelle zwar Muster erkennen, diese jedoch nicht zuverlässig kausal interpretierbar sind. Die Zuordnung von Sensordaten zu wissensbasierten Strukturen bildet damit die Grundlage für eine belastbare Ableitung von Ursachen-Wirkungs-Beziehungen und stellt einen wesentlichen Schritt vom rein prädiktiven zum kausal-prädiktiven Analyseansatz dar.

Darüber hinaus ergab sich als weitere Anforderung die Etablierung standardisierter Schnittstellen und Austauschmechanismen zwischen datengetriebener Analyse und wissensbasierter Modellierung. Für eine nachhaltige Integration müssen bidirektionale Informationsflüsse ermöglicht werden, sodass analytische Ergebnisse nicht nur Wissen nutzen, sondern dieses auch kontinuierlich erweitern und aktualisieren können. Standardisierte Metadatenmodelle, semantische Beschreibungssprachen und klar definierte Kommunikationsprotokolle sind hierfür essenziell, um Skalierbarkeit, Wartbarkeit und Systemoffenheit zu gewährleisten.

Im Strengeszyklus wurde deutlich, dass die Wissensmodellierung selbst nicht als rein technischer Prozess verstanden werden kann. Die Qualität der automatisierten Verknüpfung hängt maßgeblich von der Verfügbarkeit, Aktualität und Strukturierbarkeit der zugrunde liegenden Wissensquellen ab. In der praktischen Umsetzung zeigte sich, dass relevantes Wissen häufig in proprietären Systemen, Freitextdokumenten oder individuellen Erfahrungsbeständen verborgen ist und nur begrenzt automatisiert extrahiert werden kann. Der eingeschränkte Zugang zu Domänenexperten verstärkte diese Problematik zusätzlich. Daraus folgt die Anforderung, technische Konzepte zur Wissensverknüpfung stets durch organisatorische Prozesse der Wissensaufbereitung, -pflege und -validierung zu flankieren. Wissensintegration erweist sich damit als genuin sozio-technische Aufgabe.

Aus der Synthese der empirischen Ergebnisse lassen sich drei übergeordnete Anforderungen an Konzepte zur automatisierten Verknüpfung von Dokumentationswissen und Sensordaten ableiten. Erstens ist eine konsistente semantische Beschreibung industrieller Objekte, Prozesse und Zustände erforderlich, um eine einheitliche Bedeutungsbasis für die Dateninterpretation zu schaffen. Zweitens muss ein hoher Grad an Automatisierbarkeit gewährleistet sein, der durch standardisierte Schnittstellen, strukturierte Metadaten und klar definierte Austauschprozesse erreicht wird.

Drittens ist die Erklärbarkeit der aus der Wissens-Daten-Verknüpfung abgeleiteten Handlungsempfehlungen von zentraler Bedeutung, da nur nachvollziehbare Ursachen-Wirkungs-Beziehungen Vertrauen schaffen und die Akzeptanz wissensbasierter Entscheidungssysteme fördern.

Das in dieser Arbeit entwickelte Referenzmodell der intelligenten Data Pipeline adressiert diese Anforderungen explizit, indem es eine dedizierte Ebene zur Wissensintegration vorsieht, die strukturierte Sensordaten und unstrukturierte Dokumentationsquellen systematisch zusammenführt. Durch diese Architektur wird eine kausal-prädiktive Wissensbasis geschaffen, auf deren Grundlage analytische Ergebnisse nicht nur beschrieben, sondern fachlich begründet interpretiert werden können. Damit legt das Referenzmodell die strukturelle Grundlage für die Ableitung präskriptiver Handlungsempfehlungen, ohne diese vorschnell algorithmisch zu determinieren. Die Verknüpfung von Daten- und Wissensebene markiert somit den entscheidenden Übergang von isolierter Mustererkennung hin zu einer wissensgestützten, kausal fundierten und perspektivisch präskriptiven Instandhaltungsstrategie.

Forschungsfrage 4:

Wie kann ein kausal-prädiktiver Instandhaltungsansatz, der durch eine intelligente Data Pipeline unterstützt wird, als Grundlage für präskriptive Instandhaltungsstrategien genutzt werden?

Die vierte Forschungsfrage zielte darauf ab zu klären, wie ein kausal-prädiktiver Instandhaltungsansatz, der durch eine intelligente Data Pipeline unterstützt wird, als tragfähige Grundlage für präskriptive Instandhaltungsstrategien genutzt werden kann. Die Beantwortung dieser Forschungsfrage integriert Erkenntnisse aus dem Relevanz-, Design- und Strengesyklus des DSR und führt diese in einer konsistenten Gesamtperspektive zusammen. Die Ergebnisse dieser Arbeit zeigen, dass eine solche Nutzung weniger in der unmittelbaren Automatisierung von Entscheidungen liegt, sondern vielmehr in der strukturierten Vorbereitung, Absicherung und Operationalisierung präskriptiver Logiken auf Basis kausal fundierter Vorhersagemodelle.

Das entwickelte Referenzmodell der intelligenten Data Pipeline ist explizit so ausgelegt, dass es über reine Zustands- oder Ereignisprognosen hinausgeht und die Ursachen-Wirkungs-Zusammenhänge zwischen Prozessparametern, Systemzuständen und beobachteten Abweichungen systematisch berücksichtigt. Die in den Fallstudien eingesetzten Analyseverfahren, insbesondere die Kombination aus datengetriebener Mustererkennung, domänenspezifischer Merkmalsbildung und kontextualisierter Interpretation, ermöglichen es, prädiktive Aussagen nicht nur zeitlich, sondern auch kausal einzuordnen. Damit liefern sie belastbare Aussagen darüber, *warum* sich ein Systemzustand verändert und *welche* Einflussgrößen hierfür maßgeblich sind.

Gerade dieser kausal-prädiktive Charakter stellt die zentrale Voraussetzung für präskriptive Instandhaltungsansätze dar. Präskription erfordert nicht allein die Prognose eines zukünftigen Ereignisses, sondern die Fähigkeit, alternative Handlungsoptionen in Relation zu ihren erwarteten Wirkungen zu bewerten. Die Ergebnisse der Arbeit zeigen, dass das Referenzmodell diese Voraussetzung erfüllt, indem es Analyseergebnisse nicht isoliert betrachtet, sondern sie in eine Wissensbasis einbettet, die technische Dokumentationen, Erfahrungswissen und historische Ereignisse strukturiert integriert. Dadurch entsteht ein semantischer Rahmen, innerhalb dessen prädiktive Ergebnisse interpretiert, plausibilisiert und weiterverarbeitet werden können.

Die Fallstudien verdeutlichen, dass die identifizierten kausal-prädiktiven Muster als wissensgenerierende Bausteine fungieren, die sukzessive zu präskriptiven Entscheidungshilfen erweitert werden können. So liefern etwa die in den Ziehkissen- und Zahnstangenantriebs-Analysen gewonnenen Zusammenhänge zwischen Prozessparametern und Verschleißzuständen eine fundierte Grundlage, um mögliche Eingriffe, wie etwa Anpassungen von Betriebsparametern, Wartungszeitpunkten oder Ersatzteilstrategien, systematisch zu bewerten. Die Arbeit zeigt jedoch bewusst auch die Grenze

dieser Erweiterung auf. Präskriptive Handlungsempfehlungen können nur dann verantwortungsvoll automatisiert werden, wenn sie auf einer stabilen, validierten und erklärbaren Wissensbasis beruhen.

Vor diesem Hintergrund ist das Referenzmodell nicht als vollständig präskriptives System konzipiert, sondern als tragfähiger Bezugsrahmen für präskriptive Instandhaltungsstrategien. Es schafft die technischen, methodischen und wissensbezogenen Voraussetzungen, um aus kausal-prädiktiven Erkenntnissen schrittweise präskriptive Entscheidungslogiken abzuleiten. Dazu zählen insbesondere die Trennung von Analyse- und Entscheidungsebene, die Versionierbarkeit von Modellen, die Rückkopplung operativer Erfahrungen in die Wissensbasis sowie die Möglichkeit, Handlungsempfehlungen zunächst als assistive, nicht automatisierte Vorschläge bereitzustellen.

Die Experteninterviews bestätigen diese Positionierung. Die Befragten bewerteten insbesondere die Möglichkeit, prädiktive Erkenntnisse transparent und kontextualisiert bereitzustellen, als zentrale Voraussetzung für eine spätere präskriptive Nutzung. Präskriptive Systeme wurden nicht als kurzfristiges Ziel, sondern als Reifestufe datengetriebener Instandhaltung verstanden, die auf Vertrauen, Nachvollziehbarkeit und organisatorischer Verankerung aufbaut. Das Referenzmodell adressiert diese Anforderungen, indem es die Entwicklung präskriptiver Funktionen nicht erzwingt, sondern methodisch vorbereitet.

Zusammenfassend lässt sich festhalten, dass der in dieser Arbeit entwickelte kausal-prädiktive Instandhaltungsansatz eine notwendige und hinreichende Grundlage für präskriptive Instandhaltungsstrategien darstellt. Das Referenzmodell der intelligenten Data Pipeline ermöglicht es, prädiktive Analysen systematisch zu erklären, zu kontextualisieren und in wissensbasierte Entscheidungsprozesse zu überführen. Präskription wird damit nicht als isolierte algorithmische Funktion verstanden, sondern als konsequente Weiterentwicklung eines stabilen, kausal fundierten und organisatorisch eingebetteten Analyse- und Wissenssystems.

8.2 Kritische Würdigung und weiterer Forschungsbedarf

Die im vorangegangenen Kapitel dargestellten Forschungsergebnisse verdeutlichen, dass mit der Entwicklung und Evaluation des Referenzmodells einer intelligenten Data Pipeline ein substantieller Beitrag zur strukturierten Umsetzung datengetriebener Instandhaltungsstrategien in industriellen Produktionsumgebungen geleistet werden konnte. Insbesondere wurde gezeigt, dass kausal-prädiktive Analyseansätze, eingebettet in eine durchgängige Daten- und Wissensarchitektur, eine tragfähige Grundlage für weiterführende präskriptive Instandhaltungsstrategien darstellen. Gleichzeitig wurde jedoch deutlich, dass sowohl auf technischer als auch auf organisatorischer und semantischer Ebene weiterhin Limitationen bestehen, die eine vollständige Ausschöpfung dieses Potenzials derzeit begrenzen. Diese Spannungsfelder markieren den Übergang von der Ergebnisdarstellung zur kritischen Würdigung der Arbeit und bilden zugleich den Ausgangspunkt für weiterführenden Forschungsbedarf.

Die vorliegende Arbeit verfolgte das Ziel, ein Referenzmodell einer intelligenten Data Pipeline zu entwickeln, das sich in bestehende Produktionsumgebungen integrieren lässt und kausal-prädiktive Instandhaltungsansätze strukturiert unterstützt. Die Forschung folgte dabei konsequent dem Paradigma des DSR und verband Konzeption, Implementierung, Anwendung und Evaluation des Artefakts in einem iterativen Erkenntniszyklus. Rückblickend hat sich dieser Ansatz als grundsätzlich geeignet erwiesen, um die Komplexität datengetriebener Produktionssysteme methodisch fundiert zu adressieren. Die enge Verzahnung von Problemraum, Lösungsentwurf und empirischer Rückspiegelung ermöglichte es, sowohl technische als auch organisationale Erkenntnisse systematisch in die Artefaktgestaltung einfließen zu lassen. Gleichzeitig zeigte sich jedoch, dass die hohe Komplexität realer Produktionsumgebungen dazu führte, dass nicht alle DSR-Zyklen in gleichem Maße empirisch geschlossen werden konnten. Einschränkungen ergaben sich insbesondere

aus dem begrenzten Zugriff auf produktive Datenströme, der fehlenden automatisierten Erschließung domänenspezifischen Wissens sowie der notwendigen Abstimmung der Forschungsaktivitäten mit laufenden betrieblichen Prozessen.

Hinsichtlich der erzielten Ergebnisse kann festgehalten werden, dass die formulierten Forschungsfragen weitgehend beantwortet werden konnten, wenngleich ihre praktische Umsetzung durch infrastrukturelle und organisatorische Rahmenbedingungen teilweise relativiert wurde. Das entwickelte Referenzmodell erwies sich als tragfähiger konzeptioneller Rahmen zur Integration heterogener Datenquellen, analytischer Verfahren und wissensbasierter Komponenten. Es adressiert damit eine zentrale Lücke zwischen datengetriebener Modellbildung und wissensgestützter Entscheidungsunterstützung und schafft die strukturellen Voraussetzungen für kausal-prädiktive Instandhaltungsansätze. Gleichzeitig wurde deutlich, dass eine vollständige Implementierung des Modells in realen Produktionsumgebungen derzeit noch durch proprietäre Systemlandschaften, fehlende semantische Standards und eingeschränkten Zugriff auf Domänenwissen behindert wird. Diese Einschränkungen mindern jedoch nicht den Erkenntniswert der Arbeit, sondern verdeutlichen vielmehr die Differenz zwischen konzeptioneller Gestaltbarkeit und industrieller Realität.

Aus theoretischer Perspektive zeigt sich, dass das Referenzmodell in der Lage ist, zentrale Anforderungen aus der Literatur zu datengetriebener Instandhaltung – etwa Modularität, Interoperabilität, Skalierbarkeit und Trennung von Analyse- und Entscheidungsebene – in einem integrierten Bezugsrahmen zusammenzuführen. Gleichzeitig bestehen konzeptionelle Limitationen. Die Demonstration stützt sich auf ausgewählte Fallstudien, deren Ergebnisse zwar unterschiedliche technische Kontexte abdecken, jedoch keine vollständige Generalisierbarkeit erlauben. Insbesondere die semantische Integration von Domänenwissen konnte nur partiell realisiert werden, da der automatisierte Zugriff auf technische Dokumentationen und deren strukturierte Aufbereitung in der Praxis stark eingeschränkt war. Damit bleibt die wissensbasierte Erweiterung kausal-prädiktiver Modelle hin zu präskriptiven Entscheidungssystemen in der vorliegenden Arbeit bewusst auf konzeptioneller Ebene verankert.

Auch auf praktischer Ebene traten deutliche Limitationen zutage. Die Umsetzung der intelligenten Data Pipeline war stark von den bestehenden IT-Architekturen geprägt, die durch proprietäre Datenformate, restriktive Sicherheitszonierungen und fragmentierte Verantwortlichkeiten gekennzeichnet waren. Diese Rahmenbedingungen führten zu erhöhtem Integrationsaufwand, zeitverzögertem Datenzugriff und eingeschränkter Flexibilität bei der Modellierung und Auswertung. Hinzu kamen organisatorische Einschränkungen, insbesondere der begrenzte Zugang zu Domänenexperten sowie das Fehlen standardisierter Prozesse zur digitalen Erfassung und Pflege von Erfahrungswissen. Diese Faktoren beeinflussten sowohl die Tiefe der kausalen Analyse als auch die Geschwindigkeit der Modelliteration und unterstreichen die Notwendigkeit, datengetriebene Instandhaltung nicht als rein technisches, sondern als sozio-technisches Gestaltungsproblem zu begreifen.

Die Experteninterviews lieferten in diesem Zusammenhang wertvolle ergänzende Erkenntnisse. Die Befragten bestätigten die Nützlichkeit und strukturelle Klarheit des Referenzmodells und hoben insbesondere dessen Modularität, Technologieoffenheit und Skalierbarkeit hervor. Gleichzeitig wurde kritisch angemerkt, dass der Nutzen datengetriebener Systeme im betrieblichen Alltag maßgeblich von der Verständlichkeit der Ergebnisse, der Transparenz der Modelle sowie der organisatorischen Einbettung abhängt. Obwohl im Rahmen der Evaluation bereits nach einer begrenzten Anzahl von Interviews eine thematische Sättigung erreicht wurde, ist die Generalisierbarkeit der Ergebnisse aufgrund der Fokussierung auf eine einzelne industrielle Branche eingeschränkt. Eine Ausweitung auf weitere Produktionsdomänen oder Branchen könnte zusätzliche Erkenntnisse über organisationsspezifische Einflussfaktoren und unterschiedliche Reifegrade datengetriebener Instandhaltung liefern.

Zusammenfassend leistet die Arbeit sowohl einen theoretischen als auch einen praktischen

Beitrag. Theoretisch erweitert sie den Stand der Forschung, indem sie ein Referenzmodell vorlegt, das kausal-prädiktive Analysen systematisch in eine wissensbasierte Architektur einbettet und damit den Übergang zu präskriptiven Strategien vorbereitet. Praktisch bietet sie einen Orientierungsrahmen für Unternehmen, die datengetriebene Instandhaltungsansätze einführen oder weiterentwickeln möchten, und zeigt konkrete Herausforderungen und Gestaltungsfelder auf. Selbstkritisch ist anzumerken, dass der Grad der technischen Umsetzung einzelner Modellkomponenten begrenzt blieb und einige methodische Entscheidungen stärker pragmatisch als systematisch motiviert waren. Gleichwohl erwiesen sich diese Entscheidungen als angemessen, um zentrale Forschungslücken adressieren und belastbare Erkenntnisse über die Gestaltbarkeit datengetriebener Instandhaltungsarchitekturen gewinnen zu können.

Aufbauend auf dieser kritischen Würdigung ergeben sich mehrere Richtungen für zukünftigen Forschungsbedarf. Ein zentraler Schwerpunkt zukünftiger Forschung betrifft die Lebenszyklusbetrachtung datengetriebener Modelle sowie die systematische Nutzung von Wissen als dynamische Ressource innerhalb industrieller Analysesysteme. Die Ergebnisse dieser Arbeit zeigen, dass kausal-prädiktive Modelle nur dann langfristig nutzbar und anschlussfähig bleiben, wenn Mechanismen zur kontinuierlichen Überwachung, Adaptation, Versionierung und kontextsensitiven Weiterentwicklung etabliert werden. Modellalterung durch veränderte Prozessbedingungen, neue Materialeigenschaften oder geänderte Betriebsstrategien stellt dabei ein strukturelles Problem dar, das nicht allein durch periodisches Nachtrainieren adressiert werden kann, sondern eine ganzheitliche Betrachtung des Modell- und Wissenslebenszyklus erfordert. Die Entwicklung selbstüberwachender, erklärbarer und adaptiver Lernsysteme bildet vor diesem Hintergrund ein zentrales Forschungsfeld.

Darüber hinaus verweisen insbesondere die im Rahmen der Experteninterviews gewonnenen Einschätzungen auf ein bislang nur unzureichend erschlossenes Potenzial neuer Technologien zur automatisierten Wissensnutzung und -generierung. Mehrere Experten betonten, dass ein erheblicher Anteil relevanten Domänenwissens nicht in formalisierten Dokumentationen, sondern in informellen Artefakten wie Wartungsprotokollen, Schichtbüchern, Freitextkommentaren oder auch mündlicher Kommunikation zwischen Instandhaltern vorliegt. Vor diesem Hintergrund eröffnet der Einsatz moderner Verfahren der Sprach- und Textverarbeitung, insbesondere aus dem Bereich des Natural Language Processing und der automatischen Spracherkennung, vielversprechende Perspektiven für die industrielle Wissenserschließung. Künftige Forschung sollte untersuchen, wie gesprochene oder textuelle Erfahrungsberichte automatisiert erfasst, semantisch analysiert und in strukturierte Wissensrepräsentationen überführt werden können, die anschließend für die Parametrisierung, Kontextualisierung und Erklärung analytischer Modelle nutzbar sind.

In diesem Zusammenhang ergibt sich ein enger Bezug zur Weiterentwicklung kausal-prädiktiver Modelle. Die automatisierte Extraktion von Ursachen-Wirkungs-Hinweisen aus sprachlichen oder textuellen Quellen könnte dazu beitragen, datengetriebene Muster mit explizitem Erfahrungswissen zu verknüpfen und damit die Erklärbarkeit sowie die Robustheit analytischer Modelle signifikant zu erhöhen. Gleichzeitig eröffnet sich die Möglichkeit, Wissenslücken in datenarmen oder selten auftretenden Fehlerszenarien zu schließen, indem qualitative Erfahrungsinformationen systematisch in die Modelllogik integriert werden. Solche Ansätze könnten langfristig die Grundlage für wissensgestützte Modellanpassungen und adaptive Entscheidungsunterstützungssysteme bilden.

Ergänzend dazu besteht weiterer Forschungsbedarf hinsichtlich der architektonischen Integration solcher Wissensverarbeitungstechnologien in industrielle Data Pipelines. Insbesondere ist zu klären, wie sprach- und textbasierte Wissensquellen versioniert, validiert und mit Sensordaten sowie analytischen Modellen synchronisiert werden können, ohne die Nachvollziehbarkeit und Verantwortlichkeit von Entscheidungen zu gefährden. Dies betrifft nicht nur technische Fragen der Systemintegration, sondern auch organisatorische Aspekte der Daten- und Wissenshoheit, der Qualitätssicherung sowie der Rollenverteilung zwischen Mensch und System.

Schließlich zeigt sich, dass die Nutzung solcher Technologien untrennbar mit Fragen der Akzeptanz, des Vertrauens und der organisationalen Einbettung verbunden ist. Zukünftige Forschung sollte daher untersuchen, wie automatisiert erschlossenes Wissen transparent dargestellt, erklärbar in Entscheidungsprozesse eingebunden und von Anwendern als unterstützend wahrgenommen werden kann. Untersuchungen zu geeigneten Change-Management-Strategien, Schulungskonzepten und Governance-Modellen erscheinen in diesem Kontext ebenso notwendig wie empirische Studien zur Interaktion zwischen datengetriebenen Systemen und erfahrungsbasiertem Handeln im industriellen Alltag.

Insgesamt verdeutlichen diese Perspektiven, dass die hier vorgestellte intelligente Data Pipeline nicht als abgeschlossene Lösung, sondern als konzeptioneller Ausgangspunkt für eine weiterführende Forschung zu verstehen ist. Zukünftige Arbeiten sollten darauf aufbauen, die technologische, methodische und organisatorische Integration datengetriebener Instandhaltung in der industriellen Praxis zu vertiefen, mit dem Ziel, eine durchgängig lernfähige, wissensgestützte und präskriptive Produktionsumgebung zu realisieren.

Literaturverzeichnis

- A.F. Ragab, Mohamed; Amr Arisha (2013). „Knowledge management and measurement: a critical review“. In: *Journal of Knowledge Management* 17.6, S. 873–901. DOI: 10.1108/JKM-12-2012-0381.
- Abd Wahab, Nur Haninie; Khairunnisa Hasikin; Khin Wee Lai; Kaijian Xia; Lulu Bei; Kai Huang; Xiang Wu (2024). „Systematic review of predictive maintenance and digital twin technologies challenges, opportunities, and best practices“. In: *PeerJ. Computer science* 10, e1943. DOI: 10.7717/peerj-cs.1943.
- Abdel-Karim, Benjamin M. (2017). *Data Science: Best Practices mit Python*. Wiesbaden: Springer Fachmedien Wiesbaden. DOI: 10.1007/978-3-658-33460-4.
- Abdullahi, Ibrahim; Stefano Longo; Mohammad Samie (2024). *Towards A Distributed Digital Twin Framework for Predictive Maintenance in Manufacturing Systems*. DOI: 10.20944/preprints202403.1357.v1.
- Acito, Frank (2023a). „Logistic Regression“. In: *Predictive Analytics with KNIME*. Hrsg. von Frank Acito. Cham: Springer Nature Switzerland, S. 125–167. ISBN: 978-3-031-45629-9. DOI: 10.1007/978-3-031-45630-5_7.
- (2023b). „Problem Definition“. In: *Predictive Analytics with KNIME*. Hrsg. von Frank Acito. Cham: Springer Nature Switzerland, S. 11–19. ISBN: 978-3-031-45629-9. DOI: 10.1007/978-3-031-45630-5_2.
- Ackerman, Samuel; Eitan Farchi; Orna Raz; Marcel Zalmanovici; Parijat Dube (2020). „Detection of data drift and outliers affecting machine learning model performance over time“. In: DOI: 10.48550/arXiv.2012.09258.
- Adler, Simon; Steffen Masik (2020). „Der digitale Zwilling für virtuelle Fabrikplanung und -betrieb“. In: *Virtual Reality und Augmented Reality in der Digitalen Produktion*. Hrsg. von Horst Orsolits; Maximilian Lackner. Wiesbaden: Springer Fachmedien Wiesbaden, S. 191–215. ISBN: 978-3-658-29008-5. DOI: 10.1007/978-3-658-29009-2_10.
- Afroze, Lameya; Silke Merkelbach; Sebastian von Enzberg; Roman Dumitrescu (2024). „Domain Knowledge Injection Guidance for Predictive Maintenance“. In: *Machine Learning for Cyber-Physical Systems*. Hrsg. von Oliver Niggemann; Jürgen Beyerer; Maria Krantz; Christian Kühnert. Bd. 18. Technologien für die intelligente Automation. Cham: Springer Nature Switzerland, S. 75–87. ISBN: 978-3-031-47061-5. DOI: 10.1007/978-3-031-47062-2_8.
- AG, Siemens (2025). *Siemens Industrial Edge*. URL: <https://www.siemens.com/de/de/produkte/automatisierung/themenfelder/industrial-edge.html> (besucht am 25.10.2025).
- Ahmad, Rosmaini; Shahrul Kamaruddin (2012). „An overview of time-based and condition-based maintenance in industrial application“. In: *Computers & Industrial Engineering* 63.1, S. 135–149. DOI: 10.1016/j.cie.2012.02.002.
- Ahmad, Shafiq; Ahmed Badwelan; Atef M. Ghaleb; Ammar Qamhan; Mohamed Sharaf; Moath Alatefi; Ammar Moohialdin (2018). „Analyzing Critical Failures in a Production Process: Is Industrial IoT the Solution?“ In: *Wireless Communications and Mobile Computing* 2018.1. DOI: 10.1155/2018/6951318.

- Aho, Timo; Outi Sievi-Korte; Terhi Kilamo; Sezin Yaman; Tommi Mikkonen (2020). „Demystifying Data Science Projects: A Look on the People and Process of Data Science Today“. In: *Product-Focused Software Process Improvement*. Hrsg. von Maurizio Morisio; Marco Torchiano; Andreas Jedlitschka. Bd. 12562. Lecture Notes in Computer Science. Cham: Springer International Publishing, S. 153–167. ISBN: 978-3-030-64147-4. DOI: 10.1007/978-3-030-64148-1_10.
- Akerkar, Rajendra; Priti Srinivas Sajja (2016). „Introduction to Data Science“. In: *Intelligent Techniques for Data Science*. Hrsg. von Rajendra Akerkar; Priti Srinivas Sajja. Cham: Springer International Publishing, S. 1–30. ISBN: 978-3-319-29205-2. DOI: 10.1007/978-3-319-29206-9_1.
- Alam, Saqib; Nianmin Yao (2019). „The impact of preprocessing steps on the accuracy of machine learning algorithms in sentiment analysis“. In: *Computational and Mathematical Organization Theory* 25.3, S. 319–335. DOI: 10.1007/s10588-018-9266-8.
- Alexandropoulos, Stamatis-Aggelos N.; Sotiris B. Kotsiantis; Michael N. Vrahatis (2019). „Data preprocessing in predictive data mining“. In: *The Knowledge Engineering Review* 34. DOI: 10.1017/S026988891800036X.
- Alhamadi, Mohammed (2020). „Challenges, Strategies and Adaptations on Interactive Dashboards“. In: *Proceedings of the 28th ACM Conference on User Modeling, Adaptation and Personalization*. Hrsg. von Tsvi Kuflik; Ilaria Torre; Robin Burke; Cristina Gena. New York: ACM, S. 368–371. ISBN: 9781450368612. DOI: 10.1145/3340631.3398678.
- Alhassan, Afnan M.; Wan Mohd Nazmee Wan Zainon (2021). „Review of Feature Selection, Dimensionality Reduction and Classification for Chronic Disease Diagnosis“. In: *IEEE Access* 9, S. 87310–87317. DOI: 10.1109/ACCESS.2021.3088613.
- Alpaydm, Ethem (2010). *Introduction to machine learning*. 2. Aufl. Adaptive Computation and Machine Learning. Cambridge: MIT Press. ISBN: 978-0262012430.
- Altan, Taylan; Lars Penter (2010). „Application of modern cushion systems to improve quality and productivity in sheet metal forming“. In: *Proceedings of the CIRP Conference Machine-Process Interactions, Vancouver*.
- Altenfelder, Kai; Dieter Schönfeld; Wolfgang Krenkler (2021). *Services Management und digitale Transformation*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-33974-6. DOI: 10.1007/978-3-658-33975-3.
- Altman, Naomi; Martin Krzywinski (2017). „Ensemble methods: bagging and random forests“. In: *Nature Methods* 14.10, S. 933–935.
- Amarasinghe, Sandaruwan Chathura (2024). „Developing Robust Deep Learning Models for Intelligent Infrastructure: Addressing Scalability, Security, and Privacy Challenges“. In: *Applied Research in Artificial Intelligence and Cloud Computing* 7.4, S. 1–10.
- Amazon Web Services, Inc. (2025). *AWS Cloud-Services*. URL: <https://aws.amazon.com/de/products> (besucht am 25. 10. 2025).
- Ambhore, Nitin; Dinesh Kamble; Satish Chinchankar; Vishal Wayal (2015). „Tool Condition Monitoring System: A Review“. In: *Materials Today: Proceedings* 2.4-5, S. 3419–3428. DOI: 10.1016/j.matpr.2015.07.317.
- Amershi, Saleema; Andrew Begel; Christian Bird; Robert DeLine; Harald Gall; Ece Kamar; Nachiappan Nagappan; Besmira Nushi; Thomas Zimmermann (2019). „Software Engi-

- neering for Machine Learning: A Case Study“. In: *2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP)*. IEEE, S. 291–300. ISBN: 978-1-7281-1760-7. DOI: 10.1109/ICSE-SEIP.2019.00042.
- Amershi, Saleema; Maya Cakmak; W. Bradley Knox; Todd Kulesza (2014). „Power to the People: The Role of Humans in Interactive Machine Learning“. In: *AI Magazine* 35.4, S. 105–120. DOI: 10.1609/aimag.v35i4.2513.
- Andonie, Răzvan (2019). „Hyperparameter optimization in learning systems“. In: *Journal of Membrane Computing* 1.4, S. 279–291. DOI: 10.1007/s41965-019-00023-0.
- Andriluka, Mykhaylo; Jasper R. R. Uijlings; Vittorio Ferrari (2018). „Fluid Annotation: A Human-Machine Collaboration Interface for Full Image Annotation“. In: DOI: 10.48550/arXiv.1806.07527.
- Angehrn, Albert A.; Hans-Jakob Lüthi (1990). „Intelligent Decision Support Systems: A Visual Interactive Approach“. In: *Interfaces* 20.6, S. 17–28. DOI: 10.1287/inte.20.6.17.
- Angelov, Plamen P.; Eduardo A. Soares; Richard Jiang; Nicholas I. Arnold; Peter M. Atkinson (2021). „Explainable artificial intelligence: an analytical review“. In: *WIREs Data Mining and Knowledge Discovery* 11.5. DOI: 10.1002/widm.1424.
- Ansari, Fazel (2019). „Knowledge Management 4.0: Theoretical and Practical Considerations in Cyber Physical Production Systems“. In: *IFAC-PapersOnLine* 52.13, S. 1597–1602. DOI: 10.1016/j.ifacol.2019.11.428.
- Ansari, Fazel; Robert Glawar; Tanja Nemeth (2019). „PriMa: a prescriptive maintenance model for cyber-physical production systems“. In: *International Journal of Computer Integrated Manufacturing* 32.4-5, S. 482–503. DOI: 10.1080/0951192X.2019.1571236.
- Ansari Chaharsoughi, Fazel (2014). „Meta-analysis of knowledge assets for continuous improvement of maintenance cost controlling“. Diss. URL: <https://dspace.ub.uni-siegen.de/handle/ubsi/840>.
- Anton, Florin; Theodor Borangiu; Silviu Răileanu; Silvia Anton (2020). „Cloud-Based Digital Twin for Robot Integration in Intelligent Manufacturing Systems“. In: *Advances in Service and Industrial Robotics*. Hrsg. von Saïd Zeghloul; Med Amine Laribi; Juan Sebastian Sandoval Arevalo. Bd. 84. Mechanisms and Machine Science. Cham: Springer International Publishing, S. 565–573. ISBN: 978-3-030-48988-5. DOI: 10.1007/978-3-030-48989-2_60.
- Antonino, Pablo Oliveira; Frank Schnicke; Zai Zhang; Thomas Kuhn (2019). „Blueprints for architecture drivers and architecture solutions for Industry 4.0 shopfloor applications“. In: *Proceedings of the 13th European Conference on Software Architecture - Volume 2*. Hrsg. von Laurence Duchien; Catia Trubiani; Riccardo Scandariato; Raffaele Mirandola; Elena Maria Navarro Martinez; Danny Weyns; Anne Kozirolek; Patrizia Scandurra; Clément Quinton. New York: ACM, S. 261–268. ISBN: 9781450371421. DOI: 10.1145/3344948.3344971.
- Apel, Harald (2018). *Instandhaltungs- und Servicemanagement: Systeme mit Industrie 4.0*. München: Fachbuchverlag Leipzig im Carl Hanser Verlag. ISBN: 978-3-446-45687-7.
- Appalapuram, Venkata Surendra Reddy (2025). „The Lakehouse Paradigm: Converging Data Lakes and Warehouses for Integrated Enterprise Analytics“. In: *Journal of Com-*

- puter Science and Technology Studies* 7.4, S. 641–648. DOI: 10.32996/jcsts.2025.7.4.75.
- Aremu, Oluseun Omotola; Adrià Salvador Palau; Ajith Kumar Parlikad; David Hyland-Wood; Peter Ross McAree (2018). „Structuring Data for Intelligent Predictive Maintenance in Asset Management“. In: *IFAC-PapersOnLine* 51.11, S. 514–519. DOI: 10.1016/j.ifacol.2018.08.370.
- Armah, G Kofi; Guangchun Luo; Ke Qin (2014). „A deep analysis of the precision formula for imbalanced class distribution“. In: *International Journal of Machine Learning and Computing* 4.5, S. 417–422.
- Armbrust, Michael; Ali Ghosi; Reynold Xin; Matei Zaharia (2021). „Lakehouse: A New Generation of Open Platforms that Unify Data Warehousing and Advanced Analytics“. In: *11th Annual Conference on Innovative Data Systems Research (CIDR '21)*.
- Arsalan, Muhammad; Muhammad Mubeen; Muhammad Bilal; Saadullah Farooq Abbasi (2024). „1D-CNN-IDS: 1D CNN-based Intrusion Detection System for IIoT“. In: *2024 29th International Conference on Automation and Computing (ICAC)*. IEEE, S. 1–4. ISBN: 979-8-3503-6088-2. DOI: 10.1109/ICAC61394.2024.10718772.
- Ashmore, Rob; Radu Calinescu; Colin Paterson (2022). „Assuring the Machine Learning Lifecycle“. In: *ACM Computing Surveys* 54.5, S. 1–39. DOI: 10.1145/3453444.
- Atkinson, Lauren Z.; Andrea Cipriani (2018). „How to carry out a literature search for a systematic review: a practical guide“. In: *BJPsych Advances* 24.2, S. 74–82. DOI: 10.1192/bja.2017.3.
- Aytas, Yusuf (2021). *Designing Big Data Platforms*. 1. Aufl. Safari, an O'Reilly Media Company. ISBN: 9781119690924.
- Bach, Benjamin; Euan Freeman; Alfie Abdul-Rahman; Cagatay Turkay; Saiful Khan; Yulei Fan; Min Chen (2023). „Dashboard Design Patterns“. In: *IEEE transactions on visualization and computer graphics* 29.1, S. 342–352. DOI: 10.1109/TVCG.2022.3209448.
- Bachhiesl, Christian Wilhelm; Sonja Maria Bachhiesl; Stefan Köchel (2018). *Intuition und Wissenschaft: Interdisziplinäre Perspektiven*. 1. Aufl. Weilerswist: Velbrück Wissenschaft. ISBN: 978-3-95832-143-4.
- Badwelan, Ahmad; Moath Alatefi; Atef M. Ghaleb; Ali M. Alsamhan; Shafiq Ahmad (2019). „Implementing IoT for the Detection of Production Machine Failures“. In: *4th North American International Conference on Industrial Engineering and Operations Management, Toronto, Canada*. IEOM Society International, S. 858–866. ISBN: 978-1-5323-5950-7.
- Baker, Michael J. (2000). „Writing a Literature Review“. In: *The Marketing Review* 1.2, S. 219–247. DOI: 10.1362/1469347002529189.
- Bakhrankova, Krystsina (2010). „Decision support system for continuous production“. In: *Industrial Management & Data Systems* 110.4, S. 591–610. DOI: 10.1108/02635571011039043.
- Banks, George C.; Haley M. Woznyj; Ryan S. Wesslen; Roxanne L. Ross (2018). „A Review of Best Practice Recommendations for Text Analysis in R (and a User-Friendly App)“. In: *Journal of Business and Psychology* 33.4, S. 445–459. DOI: 10.1007/s10869-017-9528-3.

- Bansal, Srividya K. (2014). „Towards a Semantic Extract-Transform-Load (ETL) Framework for Big Data Integration“. In: *2014 IEEE International Congress on Big Data*. IEEE, S. 522–529. ISBN: 978-1-4799-5057-7. DOI: 10.1109/BigData.Congress.2014.82.
- Bao, Fan; Guoqiang Wu; Chongxuan LI; Jun Zhu; Bo Zhang (2021). „Stability and Generalization of Bilevel Programming in Hyperparameter Optimization“. In: *Advances in Neural Information Processing Systems*. Hrsg. von M. Ranzato; A. Beygelzimer; Y. Dauphin; P.S. Liang; J. Wortman Vaughan. Bd. 34. Curran Associates, Inc., S. 4529–4541.
- Barratt, Mark; Thomas Y. Choi; Mei Li (2011). „Qualitative case studies in operations management: Trends, research outcomes, and future research implications“. In: *Journal of Operations Management* 29.4, S. 329–342. DOI: 10.1016/j.jom.2010.06.002.
- Batista, GEAPA; Diego Furtado Silva et al. (2009). „How k-nearest neighbor parameters affect its performance“. In: *Argentine symposium on artificial intelligence*. Citeseer, S. 1–12.
- Batzolis, Eleftherios; Eleni Vrochidou; George A. Papakostas (2023). „Machine Learning in Embedded Systems: Limitations, Solutions and Future Challenges“. In: *2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)*. IEEE, S. 345–350. ISBN: 979-8-3503-3286-5. DOI: 10.1109/CCWC57344.2023.10099348.
- Bauer, Thomas K.; Phillip Breidenbach; Sandra Schaffner (2018). „Big Data in der wirtschaftswissenschaftlichen Forschung“. In: *Big Data*. Hrsg. von Christian König; Jette Schröder; Erich Wiegand. Wiesbaden: Springer Fachmedien Wiesbaden, S. 129–148. ISBN: 978-3-658-20082-4. DOI: 10.1007/978-3-658-20083-1_10.
- Becker, Jörg; Patrick Delfmann; Ralf Knackstedt (2007). „Adaptive Reference Modeling: Integrating Configurative and Generic Adaptation Techniques for Information Models“. In: *Reference Modeling*. Hrsg. von Jörg Becker; Patrick Delfmann. Heidelberg: Physica-Verlag HD, S. 27–58. ISBN: 978-3-7908-1965-6. DOI: 10.1007/978-3-7908-1966-3_2.
- Becker, Matthias (2019). „Standards und Schnittstellen als Arbeitsgegenstand in Industrie 4.0-Kontexten“. In: *Industrie* 4.2, S. 109–128.
- Begoli, Edmon; Ian Goethert; Kathryn Knight (2021). „A Lakehouse Architecture for the Management and Analysis of Heterogeneous Data for Biomedical Research and Megabiobanks“. In: *2021 IEEE International Conference on Big Data (Big Data)*. IEEE, S. 4643–4651. ISBN: 978-1-6654-3902-2. DOI: 10.1109/BigData52589.2021.9671534.
- Bellavista, Paolo; Filippo Bosi; Antonio Corradi; Luca Foschini; Stefano Monti; Lorenzo Patera; Luca Poli; Domenico Scotece; Michele Solimando (2019). „Design Guidelines for Big Data Gathering in Industry 4.0 Environments“. In: *2019 IEEE 20th International Symposium on A World of Wireless, Mobile and Multimedia Networks (WoWMoM)*. IEEE, S. 1–6. ISBN: 978-1-7281-0270-2. DOI: 10.1109/WoWMoM.2019.8793033.
- Bellavista, Paolo; Alessio Mora (2019). „Edge Cloud as an Enabler for Distributed AI in Industrial IoT Applications: the Experience of the IoTwins Project“. In: *AI&IoT@AI*IA*. URL: <https://api.semanticscholar.org/CorpusID:208269154>.

- Bentaib, Mohssine; Abdelaziz Ettaoufik; Abderrahim Tragha; Mohamed Azzouazi (2024). „Storage structures in the era of big data: from data warehouse to lakehouse“. In: *Journal of Theoretical and Applied Information Technology* 102.6.
- Bentéjac, Candice; Anna Csörgő; Gonzalo Martínez-Muñoz (2021). „A comparative analysis of gradient boosting algorithms“. In: *Artificial Intelligence Review* 54.3, S. 1937–1967. DOI: 10.1007/s10462-020-09896-5.
- Bernard, Jurgen; David Sessler; Jorn Kohlhammer; Roy A. Ruddell (2019). „Using Dashboard Networks to Visualize Multiple Patient Histories: A Design Study on Post-Operative Prostate Cancer“. In: *IEEE transactions on visualization and computer graphics* 25.3, S. 1615–1628. DOI: 10.1109/TVCG.2018.2803829.
- Bernstein, Herbert (2017). *Messtechnik in der Praxis*. De Gruyter Studium. Berlin: De Gruyter. ISBN: 978-3-11-052313-3.
- (2024). „Einführung in die Sensorik und in die elektronische Messtechnik“. In: *Messelektronik und Sensoren*. Hrsg. von Herbert Bernstein. Wiesbaden: Springer Fachmedien Wiesbaden, S. 1–63. ISBN: 978-3-658-38928-4. DOI: 10.1007/978-3-658-38929-1_1.
- Bertoni, Alessandro; Tobias Larsson; Jonas Larsson; Jenny Elfsberg et al. (2017). „Mining data to design value: A demonstrator in early design“. In: *DS 87-7 Proceedings of the 21st International Conference on Engineering Design (ICED 17) Vol 7: Design Theory and Research Methodology, Vancouver, Canada, 21-25.08. 2017*, S. 021–029.
- Bertsimas, Dimitris; Nathan Kallus (2020). „From Predictive to Prescriptive Analytics“. In: *Management Science* 66.3, S. 1025–1044. DOI: 10.1287/mnsc.2018.3253.
- Bhamare, Devyani; Poonam Suryawanshi (2018). „Review on Reliable Pattern Recognition with Machine Learning Techniques“. In: *Fuzzy Information and Engineering* 10.3, S. 362–377. DOI: 10.1080/16168658.2019.1611030.
- Bian, Kewei; Rahul Priyadarshi (2024). „Machine Learning Optimization Techniques: A Survey, Classification, Challenges, and Future Research Issues“. In: *Archives of Computational Methods in Engineering*. DOI: 10.1007/s11831-024-10110-w.
- Biau, Gérard; Erwan Scornet (2016). „A random forest guided tour“. In: *TEST* 25.2, S. 197–227. DOI: 10.1007/s11749-016-0481-7.
- Biedermann, Hubert (2004). *Leistungs- und kostenorientiertes Anlagenmanagement: Gestaltungselemente zur Kostenminimierung und Effizienzsteigerung*. Reihe Praxiswissen für Ingenieure Instandhaltung. Köln: Österreichische Technisch-Wissenschaftliche Vereinigung für Instandhaltung und Anlagenwirtschaft und Instandhaltungs-Forum. ISBN: 9783824908912.
- (2008). *Ersatzteilmanagement: Effiziente Ersatzteillogistik für Industrieunternehmen*. 2. Aufl. VDI-Buch. Berlin, Heidelberg: Springer Berlin Heidelberg. ISBN: 9783540682059.
- Bilek, Emine; Felix Busch; Jochen Hartung; Carsten Scheele; Carsten Thomas; Jochen Deuse; Bernd Kühlenkötter (2012). „Intelligente Erstellung und Nutzung von Maschinendokumentation“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 107.9, S. 652–656. DOI: 10.3139/104.110815.

- Bink, Raphael; Patrick Zschech (2018). „Predictive Maintenance in der industriellen Praxis“. In: *HMD Praxis der Wirtschaftsinformatik* 55.3, S. 552–565. DOI: 10.1365/s40702-017-0378-2.
- Birkert, Arndt; Stefan Haage; Markus Straub (2013). „Werkzeugtechnik und Werkzeugherstellungsprozess“. In: *Umformtechnische Herstellung komplexer Karosserieteile*. Hrsg. von Arndt Birkert; Stefan Haage; Markus Straub. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 317–429. ISBN: 978-3-642-34669-9. DOI: 10.1007/978-3-642-34670-5_5.
- Bischl, Bernd; Martin Binder; Michel Lang; Tobias Pielok; Jakob Richter; Stefan Coors; Janek Thomas; Theresa Ullmann; Marc Becker; Anne-Laure Boulesteix; Difan Deng; Marius Lindauer (2023). „Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges“. In: *WIREs Data Mining and Knowledge Discovery* 13.2. DOI: 10.1002/widm.1484.
- Biswas, Neepa; Anamitra Sarkar; Kartick Chandra Mondal (2020). „Efficient incremental loading in ETL processing for real-time data integration“. In: *Innovations in Systems and Software Engineering* 16.1, S. 53–61. DOI: 10.1007/s11334-019-00344-4.
- Blanco, Aníbal M. (2020). „Optimization in Decision Support Systems“. In: *Decision Support Systems for Weed Management*. Hrsg. von Guillermo R. Chantre; José L. González-Andújar. Cham: Springer International Publishing, S. 39–57. ISBN: 978-3-030-44401-3. DOI: 10.1007/978-3-030-44402-0_3.
- Blockeel, Hendrik (2017). „Hypothesis Space“. In: *Encyclopedia of Machine Learning and Data Mining*. Hrsg. von Claude Sammut; Geoffrey I. Webb. Boston: Springer US, S. 629–632. ISBN: 978-1-4899-7685-7. DOI: 10.1007/978-1-4899-7687-1_373.
- Blum, Anne; Yannick Wilhelm; Steffen Klein; Christopher Schnur; Peter Reimann; Rainer Müller; Andreas Schütze (2022). „Ganzheitlicher Ablaufplan für wissensgetriebene Projekte des maschinellen Lernens in der Produktion“. In: *tm - Technisches Messen* 89.5, S. 363–383. DOI: 10.1515/teme-2022-0027.
- Botchkarev, Alexei (2018). „Evaluating Performance of Regression Machine Learning Models Using Multiple Error Metrics in Azure Machine Learning Studio“. In: *SSRN Electronic Journal*. DOI: 10.2139/ssrn.3177507.
- Bouchakwa, Mariam; Yassine Ayadi; Ikram Amous (2020). „A review on visual content-based and users’ tags-based image annotation: methods and techniques“. In: *Multimedia Tools and Applications* 79.29-30, S. 21679–21741. DOI: 10.1007/s11042-020-08862-1.
- Boufassil, Asmae; Fadwa Bouhafer; Mohamed Cherradi; Anass El Haddadi (2023). „Data Catalog: Approaches, Trends, and Future Directions“. In: *2023 17th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*. IEEE, S. 369–376. ISBN: 979-8-3503-7091-1. DOI: 10.1109/SITIS61268.2023.00067.
- Bramer, Max (2020). „Avoiding Overfitting of Decision Trees“. In: *Principles of Data Mining*. Hrsg. von Max Bramer. Undergraduate Topics in Computer Science. London: Springer London, S. 121–136. ISBN: 978-1-4471-7492-9. DOI: 10.1007/978-1-4471-7493-6_9.

- Brandau, Johannes T. (2018). *SAP HANA Search Guide: Optimierung der SAP HANA Suche in strukturierten Daten ; eine Handlungsempfehlung*. Hamburg: Diplomica Verlag GmbH. ISBN: 978-3-96146-128-8.
- Brocke, Jan vom; Alexander Simons; Björn Niehaves; Kai Riemer; Ralf Plattfaut; Anne Cleven (2009). „Reconstructing the Giant: On the Importance of Rigour in Documenting the Literature Search Process“. In:
- Burch, Michael; Marco Schmid (2023). *Dashboard design*. River Publishers series in mathematical, statistical and computational modelling for engineering. River Publishers. ISBN: 978-10-0382-395-7. DOI: 10.1201/9781032657301.
- Burnay, Corentin; Fatima Dargam; Pascale Zarate (2019). „Special issue: Data visualization for decision-making: an important issue“. In: *Operational Research* 19.4, S. 853–855. DOI: 10.1007/s12351-019-00530-z.
- Burzykowski, Tomasz; Melvin Geubbelmans; Axel-Jan Rousseau; Dirk Valkenburg (2023). „Validation of machine learning algorithms“. In: *American journal of orthodontics and dentofacial orthopedics : official publication of the American Association of Orthodontists, its constituent societies, and the American Board of Orthodontics* 164.2, S. 295–297. DOI: 10.1016/j.ajodo.2023.05.007.
- Butte, Sujata; A. R. Prashanth; Sainath Patil (2018). „Machine Learning Based Predictive Maintenance Strategy: A Super Learning Approach with Deep Neural Networks“. In: *2018 IEEE Workshop on Microelectronics and Electron Devices (WMED)*. IEEE, S. 1–5. ISBN: 978-1-5386-4953-4. DOI: 10.1109/WMED.2018.8360836.
- Buxmann, Peter; Holger Schmidt (2021). *Künstliche Intelligenz*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-61793-9. DOI: 10.1007/978-3-662-61794-6.
- Cao, Fuyuan; Jiye Liang (2011). „A data labeling method for clustering categorical data“. In: *Expert Systems with Applications* 38.3, S. 2381–2385. DOI: 10.1016/j.eswa.2010.08.026.
- Carrington, André M.; Paul W. Fieguth; Hammad Qazi; Andreas Holzinger; Helen H. Chen; Franz Mayr; Douglas G. Manuel (2020). „A new concordant partial AUC and partial c statistic for imbalanced data in the evaluation of machine learning algorithms“. In: *BMC medical informatics and decision making* 20.1, S. 4. DOI: 10.1186/s12911-019-1014-6.
- Chakraborty, Tanujit; Uttam Kumar (2023). „Loss Function“. In: *Encyclopedia of Mathematical Geosciences*. Hrsg. von B. S. Daya Sagar; Qiuming Cheng; Jennifer McKinley; Frits Agterberg. Encyclopedia of Earth Sciences Series. Cham: Springer International Publishing, S. 774–779. ISBN: 978-3-030-85039-5. DOI: 10.1007/978-3-030-85040-1_187.
- Chandra, Leona; Stefan Seidel; Shirley Gregor (2015). „Prescriptive Knowledge in IS Research: Conceptualizing Design Principles in Terms of Materiality, Action, and Boundary Conditions“. In: *2015 48th Hawaii International Conference on System Sciences*. IEEE, S. 4039–4048. ISBN: 978-1-4799-7367-5. DOI: 10.1109/HICSS.2015.485.

- Chang, Pei-Chann; T. Warren Liao; Jyun-Jie Lin; Chin-Yuan Fan (2011). „A dynamic threshold decision system for stock trading signal detection“. In: *Applied Soft Computing* 11.5, S. 3998–4010. DOI: 10.1016/j.asoc.2011.02.029.
- Charbuty, Bahzad; Adnan Abdulazeez (2021). „Classification Based on Decision Tree Algorithm for Machine Learning“. In: *Journal of Applied Science and Technology Trends* 2.01, S. 20–28. DOI: 10.38094/jastt20165.
- Chatfield, Chris (1986). „Exploratory data analysis“. In: *European Journal of Operational Research* 23.1, S. 5–13. DOI: 10.1016/0377-2217(86)90209-2.
- Chen, Chi-Ou; Ye-Qi Zhuo; Chao-Chun Yeh; Che-Min Lin; Shih-Wei Liao (2015). „Machine Learning-Based Configuration Parameter Tuning on Hadoop System“. In: *2015 IEEE International Congress on Big Data*. IEEE, S. 386–392. ISBN: 978-1-4673-7278-7. DOI: 10.1109/BigDataCongress.2015.64.
- Chen, Guangxi; Yan Cheng; Jian Xu (2008). „Cluster Reduction Support Vector Machine for Large-Scale Data Set Classification“. In: *2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application*. IEEE, S. 8–12. ISBN: 978-0-7695-3490-9. DOI: 10.1109/PACIIA.2008.43.
- Chen, Hung-Leng; Kun-Ta Chuang; Ming-Syan Chen (2008). „On Data Labeling for Clustering Categorical Data“. In: *IEEE Transactions on Knowledge and Data Engineering* 20.11, S. 1458–1472. DOI: 10.1109/TKDE.2008.81.
- Chen, J. J.; C-A Tsai; H. Moon; H. Ahn; J. J. Young; C-H Chen (2006). „Decision threshold adjustment in class prediction“. In: *SAR and QSAR in environmental research* 17.3, S. 337–352. DOI: 10.1080/10659360600787700.
- Chen, Jun; Songting Chen; Elke A. Rundensteiner (2003). „A Transactional Model for Data Warehouse Maintenance“. In: *Conceptual Modeling — ER 2002*. Hrsg. von Gerhard Goos; Juris Hartmanis; Jan van Leeuwen; Stefano Spaccapietra; Salvatore T. March; Yahiko Kambayashi. Bd. 2503. Lecture Notes in Computer Science. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 247–262. ISBN: 978-3-540-44277-6. DOI: 10.1007/3-540-45816-6_27.
- Chen, Shenglei; Geoffrey I. Webb; Linyuan Liu; Xin Ma (2020). „A novel selective naïve Bayes algorithm“. In: *Knowledge-Based Systems* 192, S. 105361. DOI: 10.1016/j.knosys.2019.105361.
- Chen, Siyuan; Ebru Turanoglu Bekar; Jon Bokrantz; Anders Skoogh (2025). „AI-enhanced digital twins in maintenance: Systematic review, industrial challenges, and bridging research–practice gaps“. In: *Journal of Manufacturing Systems* 82, S. 678–699. DOI: 10.1016/j.jmsy.2025.07.006.
- Cheng, Liying; Xingxuan Li; Lidong Bing (2023). „Is GPT-4 a Good Data Analyst?“ In: DOI: 10.48550/arXiv.2305.15038.
- Cherdantseva, Yulia; Jeremy Hilton; Omer Rana; Wendy Ivins (2016). „A multifaceted evaluation of the reference model of information assurance & security“. In: *Computers & Security* 63, S. 45–66. DOI: 10.1016/j.cose.2016.09.007.
- Chi, Mingmin; Antonio Plaza; Jon Atli Benediktsson; Zhongyi Sun; Jinsheng Shen; Yangyong Zhu (2016). „Big Data for Remote Sensing: Challenges and Opportunities“. In: *Proceedings of the IEEE* 104.11, S. 2207–2219. DOI: 10.1109/JPROC.2016.2598228.

- Chicco, Davide; Matthijs J. Warrens; Giuseppe Jurman (2021). „The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation“. In: *PeerJ. Computer science* 7, e623. DOI: 10.7717/peerj-cs.623.
- Chitraju Gopal Varma, Santhosh (2025). *Monitoring, Retraining, and Governance: Key Steps in Managing the ML Model Lifecycle*. DOI: 10.2139/ssrn.5226797.
- Chopra, Meenu; Neha Saini; Satish Kumar; Arup Varma; Sachin Kumar Mangla; Weng Marc Lim (2021). „Past, present, and future of knowledge management for business sustainability“. In: *Journal of Cleaner Production* 328. DOI: 10.1016/j.jclepro.2021.129592.
- Choubey, Suresh; Ryan G. Benton; Tom Johnsten (2020). „A Holistic End-to-End Prescriptive Maintenance Framework“. In: *Data-Enabled Discovery and Applications* 4.1. DOI: 10.1007/s41688-020-00045-z.
- Chuah, Joshua; Uwe Kruger; Ge Wang; Pingkun Yan; Juergen Hahn (2022). „Framework for Testing Robustness of Machine Learning-Based Classifiers“. In: *Journal of personalized medicine* 12.8. DOI: 10.3390/jpm12081314.
- Ciocioiu, Luminita; Carys E. Siemieniuch; Ella-Mae Hubbard (2017). „From preventative to predictive maintenance: The organisational challenge“. In: *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 231.10, S. 1174–1185. DOI: 10.1177/0954409717701785.
- Çınar, Zeki Murat; Abubakar Abdussalam Nuhu; Qasim Zeeshan; Orhan Korhan; Mohammed Asmael; Babak Safaei (2020). „Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0“. In: *Sustainability* 12.19, S. 8211. DOI: 10.3390/su12198211.
- Coe, J. P. (2018). „Machine Learning Configuration Interaction“. In: *Journal of chemical theory and computation* 14.11, S. 5739–5749. DOI: 10.1021/acs.jctc.8b00849.
- Compare, Michele; Piero Baraldi; Enrico Zio (2020). „Challenges to IoT-Enabled Predictive Maintenance for Industry 4.0“. In: *IEEE Internet of Things Journal* 7.5, S. 4585–4597. DOI: 10.1109/JIOT.2019.2957029.
- Connor, J. T.; R. D. Martin; L. E. Atlas (1994). „Recurrent neural networks and robust time series prediction“. In: *IEEE transactions on neural networks* 5.2, S. 240–254. DOI: 10.1109/72.279188.
- Consilvio, Alice; Paolo Sanetti; Davide Anguita; Carlo Crovetto; Carlo Dambra; Luca Oneto; Federico Papa; Nicola Sacco (2019). „Prescriptive Maintenance of Railway Infrastructure: From Data Analytics to Decision Support“. In: *2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MTITS)*. IEEE, S. 1–10. ISBN: 978-1-5386-9484-8. DOI: 10.1109/MTITS.2019.8883331.
- Cooper, Harris M. (1988). „Organizing knowledge syntheses: A taxonomy of literature reviews“. In: *Knowledge in Society* 1.1, S. 104–126. DOI: 10.1007/BF03177550.
- Creswell, John W. (2006). *Research design: Qualitative, quantitative, and mixed methods approaches*. 2. Aufl. Thousand Oaks: Sage Publ. ISBN: 0761924426.

- Crickard, Paul (2020). *Data Engineering with Python: Work with Massive Datasets to Design Data Models and Automate Data Pipelines Using Python*. Birmingham: Packt Publishing Limited. ISBN: 978-1-83921-418-9.
- Cui, Yesheng; Sami Kara; Ka C. Chan (2020). „Monitoring and Control of Unstructured Manufacturing Big Data“. In: *2020 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, S. 928–932. DOI: 10.1109/IEEM45057.2020.9309975.
- Culotta, Aron; Pallika Kanani; Michael Wick; Andrew Mccallum (Jan. 2007). „Author Disambiguation using Error-driven Machine Learning with a Ranking Loss Function“. In: *AAAI Workshop - Technical Report*.
- Czichos, Horst (2019). *Mechatronik: Grundlagen und Anwendungen technischer Systeme*. 4. Aufl. Wiesbaden und Heidelberg: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-26293-8.
- Daily, Jim; Jeff Peterson (2017). „Predictive Maintenance: How Big Data Analysis Can Improve Maintenance“. In: *Supply Chain Integration Challenges in Commercial Aerospace*. Hrsg. von Klaus Richter; Johannes Walther. Cham: Springer International Publishing, S. 267–278. ISBN: 978-3-319-46154-0. DOI: 10.1007/978-3-319-46155-7_18.
- Das, Tathagata; Yuan Zhong; Ion Stoica; Scott Shenker (11032014). „Adaptive Stream Processing using Dynamic Batch Sizing“. In: *Proceedings of the ACM Symposium on Cloud Computing*. Hrsg. von Ed Lazowska; Doug Terry; Remzi H. Arpaci-Dusseau; Johannes Gehrke. New York: ACM, S. 1–13. ISBN: 9781450332521. DOI: 10.1145/2670979.2670995.
- Al-Debei, Mutaz M (2011). „Data warehouse as a backbone for business intelligence: issues and challenges“. In: *European Journal of Economics, Finance and Administrative Sciences* 33.1, S. 153–166.
- Demirović, Emir; Peter J. Stuckey (2021). „Optimal Decision Trees for Nonlinear Metrics“. In: *Proceedings of the AAAI Conference on Artificial Intelligence* 35.5, S. 3733–3741. DOI: 10.1609/aaai.v35i5.16490.
- Denkena, Berend; Justin Schmidt; Max Krüger (2014). „Data Mining Approach for Knowledge-based Process Planning“. In: *Procedia Technology* 15, S. 406–415. DOI: 10.1016/j.protcy.2014.09.095.
- Denyer, David; David Tranfield; Joan Ernst van Aken (2008). „Developing Design Propositions through Research Synthesis“. In: *Organization Studies* 29.3, S. 393–413. DOI: 10.1177/0170840607088020.
- Dern, Gernot (2006). *Management von IT-Architekturen*. Edition CIO. Wiesbaden: Springer Fachmedien. ISBN: 978-3-8348-9061-0.
- Despres, Charles; Daniele Chauvel (1999). „Knowledge management(s)“. In: *Journal of Knowledge Management* 3.2, S. 110–123. DOI: 10.1108/13673279910275567.
- DIN 31051:2019-06 (2019). *Grundlagen der Instandhaltung*. Berlin. DOI: 10.31030/3048531.
- DIN 77005-1:2018-09 (2018). *Lebenslaufakte für technische Anlagen_ - Teil_1: Strukturelle und inhaltliche Festlegungen*. Berlin. DOI: 10.31030/2855984.

- DIN 8580:2022-12 (2022). *Fertigungsverfahren_ - Begriffe, Einteilung*. Berlin. DOI: 10.31030/3217872.
- DIN EN 13306 (2017). *Instandhaltung - Begriffe der Instandhaltung*. Berlin. DOI: 10.31030/2641990.
- Diouf, Papa Senghane; Aliou Boly; Samba Ndiaye (2018). „Variety of data in the ETL processes in the cloud: State of the art“. In: *2018 IEEE International Conference on Innovative Research and Development (ICIRD)*. IEEE, S. 1–5. ISBN: 978-1-5386-5696-9. DOI: 10.1109/ICIRD.2018.8376308.
- Dobbert, Paul; Safa Evirgen (2023). „Vorrichtung und Verfahren zur Vorhersage des Zustands von einem Zahnstangen- Linearantrieb“. DE 10 2021 004 265 B4. URL: <https://depatisnet.dpma.de/DepatisNet/depatisnet?action=bibdat&docid=DE102021004265B4>.
- Dogan, Yahya (2023). „A New Global Pooling Method for Deep Neural Networks: Global Average of Top-K Max-Pooling“. In: *Traitement du Signal* 40.2, S. 577–587. DOI: 10.18280/ts.400216.
- Domingos, Pedro (2012). „A few useful things to know about machine learning“. In: *Communications of the ACM* 55.10, S. 78–87. DOI: 10.1145/2347736.2347755.
- Dong, Tianxi; Jason Triche (2020). „A longitudinal analysis of job skills for entry-level data analysts“. In: *Journal of Information Systems Education* 31.4, S. 312.
- Donoho, David (2017). „50 Years of Data Science“. In: *Journal of Computational and Graphical Statistics* 26.4, S. 745–766. DOI: 10.1080/10618600.2017.1384734.
- Dooley, Larry M. (2002). „Case Study Research and Theory Building“. In: *Advances in Developing Human Resources* 4.3, S. 335–354. DOI: 10.1177/1523422302043007.
- Dörn, Sebastian (2018). *Programmieren für Ingenieure und Naturwissenschaftler*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-54303-0. DOI: 10.1007/978-3-662-54304-7.
- Dowding, Dawn; Jacqueline A. Merrill (2018). „The Development of Heuristics for Evaluation of Dashboard Visualizations“. In: *Applied clinical informatics* 9.3, S. 511–518. DOI: 10.1055/s-0038-1666842.
- Dumre, Prabin; Somnath Bhattarai; H. K. Shashikala (2024). „Optimizing Linear Regression Models: A Comparative Study of Error Metrics“. In: *2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS)*. IEEE, S. 1856–1861. ISBN: 979-8-3503-8747-6. DOI: 10.1109/ICTACS62700.2024.10840719.
- Dziugaite, Gintare Karolina; Daniel M. Roy; Zoubin Ghahramani (2015). „Training generative neural networks via Maximum Mean Discrepancy optimization“. In: DOI: 10.48550/arXiv.1505.03906.
- Ebiloma, David Ojimaajo; Clinton Ohis Aigbavboa; Chimay Anumba (2023). „Towards Digital Twin Maintenance Management of Health Facilities in Nigeria: The Need for Maintenance Documentation“. In: *Buildings* 13.5, S. 1339. DOI: 10.3390/buildings13051339.
- Eisenbürger, Anita; Daniel Otten; Anselm Hudde; Frank Hopfgartner (2024). „Training Gradient Boosted Decision Trees on Tabular Data Containing Label Noise for Classification Tasks“. In: DOI: 10.48550/arXiv.2409.08647.

- Eisenhardt, Kathleen M. (1989). „Building Theories from Case Study Research“. In: *Academy of Management Review* 14.4, S. 532–550. DOI: 10.5465/amr.1989.4308385.
- Elmasri, Ramez; Sham Navathe (2016). *Fundamentals of database systems*. 7. Aufl. Harlow: Pearson. ISBN: 978-1-292-09762-6.
- Ertel, Wolfgang (2021). *Grundkurs Künstliche Intelligenz*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-32074-4. DOI: 10.1007/978-3-658-32075-1.
- Esswein, Werner; Sabine Zumpe; Nicole Sunke (2004). „Identifying the quality of e-commerce reference models“. In: *Proceedings of the 6th international conference on Electronic commerce - ICEC '04*. Hrsg. von Marijn Janssen; Henk G. Sol; René W. Wagenaar. New York: ACM Press, S. 288. ISBN: 1581139306. DOI: 10.1145/1052220.1052257.
- Evirgen, Safa; Maylin Wartenberg (2024). „Steps and Challenges in Analyzing Real Sensor Data from a Productive Press Shop and its Value for Predictive Maintenance Application“. In: *International Journal on Cybernetics & Informatics* 13.3, S. 01–10. DOI: 10.5121/ijci.2024.130301.
- Falkner, Stefan; Aaron Klein; Frank Hutter (2018). „BOHB: Robust and Efficient Hyperparameter Optimization at Scale“. In: *Proceedings of the 35th International Conference on Machine Learning*. Hrsg. von Jennifer Dy; Andreas Krause. Bd. 80. Proceedings of Machine Learning Research. PMLR, S. 1437–1446. URL: <https://proceedings.mlr.press/v80/falkner18a.html>.
- Fallucchi, Francesca; Michele Petito; Ernesto William de Luca (2019). „Analysing and Visualising Open Data Within the Data and Analytics Framework“. In: *Metadata and Semantic Research*. Hrsg. von Emmanouel Garoufallou; Fabio Sartori; Rania Siatri; Marios Zervas. Bd. 846. Communications in Computer and Information Science. Cham: Springer International Publishing, S. 135–146. ISBN: 978-3-030-14400-5. DOI: 10.1007/978-3-030-14401-2_13.
- Fang, Huang (2015). „Managing data lakes in big data era: What’s a data lake and why has it became popular in data management ecosystem“. In: *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*. IEEE, S. 820–824. ISBN: 978-1-4799-8728-3. DOI: 10.1109/CYBER.2015.7288049.
- Fang, Lizhe; Yifei Wang; Zhaoyang Liu; Chenheng Zhang; Stefanie Jegelka; Jinyang Gao; Bolin Ding; Yisen Wang (2024). „What is Wrong with Perplexity for Long-context Language Modeling?“. In: DOI: 10.48550/arXiv.2410.23771.
- Fanti, M. P.; G. Iacobellis; W. Ukovich; V. Boschian; G. Georgoulas; C. Stylios (2015). „A simulation based Decision Support System for logistics management“. In: *Journal of Computational Science* 10, S. 86–96. DOI: 10.1016/j.jocs.2014.10.003.
- Fatima, Anosh; Nosheen Nazir; Muhammad Gufran Khan (2017). „Data Cleaning In Data Warehouse: A Survey of Data Pre-processing Techniques and Tools“. In: *International Journal of Information Technology and Computer Science* 9.3, S. 50–61. DOI: 10.5815/ijitcs.2017.03.06.
- Fatima, Meherwar; Maruf Pasha (2017). „Survey of Machine Learning Algorithms for Disease Diagnostic“. In: *Journal of Intelligent Learning Systems and Applications* 09.01, S. 1–16. DOI: 10.4236/jilsa.2017.91001.

- Fayyad, U; G Piatetsky-Shapiro; P Smyth (Dez. 1996). „Knowledge discovery and data mining: Towards a unifying framework“. In: URL: <https://www.osti.gov/biblio/421260>.
- Fayyad, Usama; Gregory Piatetsky-Shapiro; Padhraic Smyth (1996). „From data mining to knowledge discovery in databases“. In: *AI magazine* 17.3.
- Feldschmid, Andreas (2009). „Konzeption und prototypische Implementierung eines Steuerungscockpits im Kontext des Managements von Unternehmensarchitektur“. In: *Hochschule Rosenheim*.
- Feng, Wang; Li Xia; Zhang Bing; Wang Xiang-yu (2013). „A study on time series models and criterion rules based on condition monitoring of the tracking test system“. In: *Proceedings 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer (MEC)*. IEEE, S. 663–667. ISBN: 978-1-4799-2565-0. DOI: 10.1109/MEC.2013.6885146.
- Fenton, Norman; Martin Neil; Anthony Constantinou (2020). „Book review“. In: *Artificial Intelligence* 284, S. 103286. DOI: 10.1016/j.artint.2020.103286.
- Ferrari, Paolo; Alessandra Flammini; Emiliano Sisinni; Stefano Rinaldi; Dennis Brandao; Murilo Silveira Rocha (2018). „Delay Estimation of Industrial IoT Applications Based on Messaging Protocols“. In: *IEEE Transactions on Instrumentation and Measurement* 67.9, S. 2188–2199. DOI: 10.1109/TIM.2018.2813798.
- Fettke, Peter; Peter Loos (2003). „Classification of reference models: a methodology and its application“. In: *Information Systems and e-Business Management* 1.1, S. 35–53. DOI: 10.1007/BF02683509.
- (2004). „Referenzmodellierungsforschung“. In: *WIRTSCHAFTSINFORMATIK* 46.5, S. 331–340. DOI: 10.1007/BF03250947.
- Few, Stephen (2006). *Information dashboard design: The effective visual communication of data*. 1. Aufl. Sebastopol: O'Reilly & Associates. ISBN: 0596100167.
- Filz, Marc-André; Jan Philipp Bosse; Christoph Herrmann (2024). „Digitalization platform for data-driven quality management in multi-stage manufacturing systems“. In: *Journal of Intelligent Manufacturing* 35.6, S. 2699–2718. DOI: 10.1007/s10845-023-02162-9.
- Fiser, Petr; Jan Schmidt; Jiri Balcerek (2014). „Sources of bias in EDA tools and its influence“. In: *17th International Symposium on Design and Diagnostics of Electronic Circuits & Systems*. IEEE, S. 258–261. ISBN: 978-1-4799-4558-0. DOI: 10.1109/DDECS.2014.6868803.
- Focke, Markus; Jörn Steinbeck (2018). *Steigerung der Anlagenproduktivität durch OEE-Management: Definitionen, Vorgehen und Methoden - von manuell bis Industrie 4.0*. essentials. Wiesbaden: Springer Gabler. ISBN: 978-3-658-21455-5. DOI: 10.1007/978-3-658-21456-2.
- Fortoul-Diaz, Jesus Anselmo; Luis Antonio Carrillo-Martinez; Adolfo Centeno-Tellez; Froylan Cortes-Santacruz; Ivan Olmos-Pineda; Roberto Rafael Flores-Quintero (2023). „A Smart Factory Architecture Based on Industry 4.0 Technologies: Open-Source Software Implementation“. In: *IEEE Access* 11, S. 101727–101749. DOI: 10.1109/ACCESS.2023.3316116.

- Frank, Ulrich (2006). „Evaluation of Reference Models“. In: *Reference Modeling for Business Systems Analysis*. Hrsg. von Peter Fettke; Peter Loos. IGI Global. ISBN: 9781599040547. DOI: 10.4018/9781599040547.ch006.
- Freeman, Elizabeth A.; Gretchen G. Moisen; John W. Coulston; Barry T. Wilson (2016). „Random forests and stochastic gradient boosting for predicting tree canopy cover: comparing tuning processes and model performance“. In: *Canadian Journal of Forest Research* 46.3, S. 323–339. DOI: 10.1139/cjfr-2014-0562.
- Fu, Xin; Yun Wang; Haoyu Dong; Weiwei Cui; Haidong Zhang (2019). „Visualization Assessment: A Machine Learning Approach“. In: *2019 IEEE Visualization Conference (VIS)*. IEEE, S. 126–130. ISBN: 978-1-7281-4941-7. DOI: 10.1109/VISUAL.2019.8933570.
- Fuchslueger, Jörg (2016). „Semantische Analyse unstrukturierter Daten“. In: DOI: 10.25364/1.3:2016.1.5.
- Gade, Kishore Reddy (2022). „Data Lakehouses: Combining the Best of Data Lakes and Data Warehouses“. In: *Journal of Computational Innovation* 2.1.
- Gami, Sandip; Kevin Shah; Chandrasekhar Rao Katru; Sevinthi Kali Sankar Nagarajan (Dez. 2024). „Interactive Data Quality Dashboard: Integrating Real-Time Monitoring with Predictive Analytics for Proactive Data Management“. In: *International Journal of Computer Sciences and Engineering* 12, S. 5. DOI: 10.26438/ijcse/v12i12.4247.
- García, Salvador; Julián Luengo; Francisco Herrera (2014). *Data Preprocessing in Data Mining*. 1. Aufl. Intelligent Systems Reference Library. Springer-Verlag. ISBN: 978-3-319-10247-4.
- García, Salvador; Sergio Ramírez-Gallego; Julián Luengo; José Manuel Benítez; Francisco Herrera (2016). „Big data preprocessing: methods and prospects“. In: *Big Data Analytics* 1.1. DOI: 10.1186/s41044-016-0014-0.
- Gardner, Howard; Katie Davis; Joanna Christodoulou; Scott Seider (2011). „The Theory of Multiple Intelligences“. In: *The Cambridge Handbook of Intelligence*. Hrsg. von Robert J. Sternberg; Barry L. Kaufman. Cambridge, S. 485–503.
- Garg, Amik; SG Deshmukh (2006). „Maintenance management: literature review and directions“. In: *Journal of quality in maintenance engineering* 12.3, S. 205–238.
- Gausemeier, Jürgen (2013). „Digitale Prozesskette zur effizienten technischen Produktdokumentation“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 108.3, S. 101–102. DOI: 10.3139/104.013030.
- Gdanitz, Natalie; Sabine Janzen; Hannah Stein; Amin Harig; Wolfgang Maaß (2023). „ADA: Automatic Data Annotation for Data Ecosystems.“ In: *ISWC (Posters/Demos/Industry)*.
- Genç, Burkay; Hüseyin Tunç (2019). „Optimal training and test sets design for machine learning“. In: *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, S. 1534–1545. DOI: 10.3906/elk-1807-212.
- Genesereth, Michael R.; Arthur M. Keller; Oliver M. Duschka (1997). „Infomaster“. In: *ACM SIGMOD Record* 26.2, S. 539–542. DOI: 10.1145/253262.253400.

- Gentsch, Peter (2018). *Künstliche Intelligenz für Sales, Marketing und Service*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-19146-7. DOI: 10.1007/978-3-658-19147-4.
- Geoffrion, A.; S. Maturana (1995). „Generating optimization-based decision support systems“. In: *Proceedings of the Twenty-Eighth Hawaii International Conference on System Sciences, vol.3*. IEEE Comput. Soc. Press, S. 439–448. ISBN: 0-8186-6940-3. DOI: 10.1109/HICSS.1995.375626.
- George, Gerard; Ernst C. Osinga; Dovev Lavie; Brent A. Scott (2016). „Big Data and Data Science Methods for Management Research“. In: *Academy of Management Journal* 59.5, S. 1493–1507. DOI: 10.5465/amj.2016.4005.
- Ghosh, Samiran; Saptarsi Goswami; Amlan Chakrabarti (2011). „Outlier detection from ETL execution trace“. In: *2011 3rd International Conference on Electronics Computer Technology*. IEEE, S. 343–347. ISBN: 978-1-4244-8678-6. DOI: 10.1109/ICECTECH.2011.5942112.
- Ghosh Chowdhury, Arnab; Marvin Illian; Lukasz Wisniewski; Jurgen Jasperneite (2020). „An Approach for Data Pipeline with Distributed Query Engine for Industrial Applications“. In: *2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. IEEE, S. 1005–1008. ISBN: 978-1-7281-8956-7. DOI: 10.1109/ETFA46521.2020.9212050.
- Ghotkar, MM (2021). „Comparative study of opc ua, mqtt, and onem2m for interoperable industrial iot communication“. In: *Elementary Education Online* 20.6, S. 6476–6488.
- Giacotto, Alessandro; {Antonello Celio} {Pereira Mesquita}; Henrique {Costa Marques}; Alberto Martinetti (2024). „Holistic and scalable smart optimization framework for prescriptive maintenance“. In: 34th Congress of the International Council of Aeronautical Sciences, ICAS 2024, ICAS 2024 ; Conference date: 09-09-2024 Through 13-09-2024. URL: <https://www.icas2024.com>.
- Giacotto, Alessandro; Henrique Costa Marques; Alberto Martinetti (2025). „Prescriptive maintenance: a comprehensive review of current research and future directions“. In: *Journal of Quality in Maintenance Engineering* 31.1, S. 129–173. DOI: 10.1108/JQME-07-2023-0064.
- Gilmore, Stephen; László Gönczy; Nora Koch; Philip Mayer; Mirco Tribastone; Dániel Varró (2011). „Non-functional properties in the model-driven development of service-oriented systems“. In: *Software & Systems Modeling* 10.3, S. 287–311. DOI: 10.1007/s10270-010-0155-y.
- Glaser, Barney G.; Anselm L. Strauss (2017). *The Discovery of Grounded Theory*. Routledge. ISBN: 9780203793206. DOI: 10.4324/9780203793206.
- Gläser, Jochen; Grit Laudel (2010). *Experteninterviews und qualitative Inhaltsanalyse als Instrumente rekonstruierender Untersuchungen*. 4. Aufl. Lehrbuch. Wiesbaden: VS Verlag. ISBN: 9783531172385.
- Glawar, Robert; Fazel Ansari; Csaba Kardos; Kurt Matyas; Wilfried Sihn (2019). „Conceptual Design of an Integrated Autonomous Production Control Model in association with a Prescriptive Maintenance Model (PriMa)“. In: *Procedia CIRP* 80, S. 482–487. DOI: 10.1016/j.procir.2019.01.047.

- Glawar, Robert; Zsolt Kemeny; Tanja Nemeth; Kurt Matyas; Laszlo Monostori; Wilfried Sihn (2016). „A Holistic Approach for Quality Oriented Maintenance Planning Supported by Data Mining Methods“. In: *Procedia CIRP* 57, S. 259–264. DOI: 10.1016/j.procir.2016.11.045.
- Goodfellow, Ian; Yoshua Bengio; Aaron Courville (2016). *Deep learning*. Adaptive Computation and Machine Learning. Cambridge und London: MIT Press. ISBN: 978-0-262-03561-3.
- Gorawski, M.; K. Pasterak; A. Gorawska (2023). „The stream data warehouse: Page replacement algorithms and quality of service metrics“. In: *Future Generation Computer Systems* 142, S. 212–227. DOI: 10.1016/j.future.2023.01.003.
- Gosain, Anjana; Amar Arora (2015). „Security Issues in Data Warehouse: A Systematic Review“. In: *Procedia Computer Science* 48, S. 149–157. DOI: 10.1016/j.procs.2015.04.164.
- Gotmare, Akhilesh; Nitish Shirish Keskar; Caiming Xiong; Richard Socher (2018). „A Closer Look at Deep Learning Heuristics: Learning rate restarts, Warmup and Distillation“. In: DOI: 10.48550/arXiv.1810.13243.
- Graf, Marcel; Holger Müller (2021). „Data-Analytics-Projekte in der Beschaffung erfolgreich umsetzen“. In: *Logistik in Wissenschaft und Praxis*. Hrsg. von Roy Fritzsche; Stefan Winter; Jacob Lohmer. Wiesbaden: Springer Fachmedien Wiesbaden, S. 211–239. ISBN: 978-3-658-33479-6. DOI: 10.1007/978-3-658-33480-2_9.
- Graves, Alex (2013). „Generating Sequences With Recurrent Neural Networks“. In: DOI: 10.48550/arXiv.1308.0850.
- (2016). „Adaptive Computation Time for Recurrent Neural Networks“. In: DOI: 10.48550/arXiv.1603.08983.
- Gregor (2006). „The Nature of Theory in Information Systems“. In: *MIS Quarterly* 30.3, S. 611. DOI: 10.2307/25148742.
- Gregor, Shirley; Alan R. Hevner (2013). „Positioning and Presenting Design Science Research for Maximum Impact“. In: *MIS Quarterly* 37.2, S. 337–355. DOI: 10.25300/MISQ/2013/37.2.01.
- Gretton, Arthur; Karsten M. Borgwardt; Malte J. Rasch; Bernhard Schölkopf; Alexander Smola (März 2012). „A kernel two-sample test“. In: *J. Mach. Learn. Res.* 13, S. 723–773.
- Greving, Bert (2009). „Messen und Skalieren von Sachverhalten“. In: *Methodik der empirischen Forschung*. Hrsg. von Sönke Albers; Daniel Klapper; Udo Konradt; Achim Walter; Joachim Wolf. Wiesbaden: Gabler Verlag, S. 65–78. ISBN: 978-3-8349-1703-4. DOI: 10.1007/978-3-322-96406-9_5.
- Grimmeisen, Benedikt; Mohammad Chegini; Andreas Theissler (2023). „VisGIL: machine learning-based visual guidance for interactive labeling“. In: *The Visual Computer* 39.10, S. 5097–5119. DOI: 10.1007/s00371-022-02648-2.
- Grosse, Sven (2019). „Theologie als Wissenschaft und die Scholzschen Postulate“. In: *Theologie und Wissenschaftstheorie*. Hrsg. von Sven Grosse. Brill | Schöningh, S. 21–111. ISBN: 9783506701688. DOI: 10.30965/9783657701681_005.

- Großmann, Knut; Lars Penter; CC Schenke; André Hardtmann (2013). „Systematische Berücksichtigung der Ziehkissenanlage von Umformpressen in FE-Prozesssimulationen“. In: *Conference: Sächsische Fachtagung für Umformtechnik, Dresden*. Bd. 20.
- Gu, Jiuxiang; Zhenhua Wang; Jason Kuen; Lianyang Ma; Amir Shahroudy; Bing Shuai; Ting Liu; Xingxing Wang; Gang Wang; Jianfei Cai; Tsuhan Chen (2018). „Recent advances in convolutional neural networks“. In: *Pattern Recognition* 77, S. 354–377. DOI: 10.1016/j.patcog.2017.10.013.
- Günther, Johannes; Patrick M. Pilarski; Gerhard Helfrich; Hao Shen; Klaus Diepold (2014). „First Steps Towards an Intelligent Laser Welding Architecture Using Deep Neural Networks and Reinforcement Learning“. In: *Procedia Technology* 15, S. 474–483. DOI: 10.1016/j.protcy.2014.09.007.
- Gupta, Shweta; Abhigna Ragala (2024). „Embedded machine learning“. In: *Embedded Devices and Internet of Things*. Hrsg. von Adesh Kumar; Surajit Mondal; Gaurav Verma; Prashant Mani. Boca Raton: CRC Press, S. 267–284. ISBN: 9781003510420. DOI: 10.1201/9781003510420-15.
- Gurjanov, A. V.; D. A. Zakoldaev; A. V. Shukalov; I. O. Zharinov (2018). „Organization of project works in Industry 4.0 digital item designing companies“. In: *Journal of Physics: Conference Series* 1015.5, S. 052034. DOI: 10.1088/1742-6596/1015/5/052034.
- Gutsche, Katja; Bernd-Friedrich Voigt (2018). „Wandel von Instandhaltungsarbeit“. In: *Betriebliche Instandhaltung*. Hrsg. von Jens Reichel; Gerhard Müller; Jean Haeffs. VDI-Buch. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 161–180. ISBN: 978-3-662-53134-1. DOI: 10.1007/978-3-662-53135-8_10.
- Haase, Tina (2017). „Industrie 4.0: Technologiebasierte Lern- und Assistenzsysteme für die Instandhaltung“. Dissertation. Magdeburg: Fakultät für Maschinenbau, Otto-von-Guericke-Universität Magdeburg und W. Bertelsmann Verlag.
- Hai, Rihan; Sandra Geisler; Christoph Quix (2016). „Constance: An Intelligent Data Lake System“. In: *Proceedings of the 2016 International Conference on Management of Data*. Hrsg. von Fatma Özcan; Georgia Koutrika; Sam Madden. New York: ACM, S. 2097–2100. ISBN: 9781450335317. DOI: 10.1145/2882903.2899389.
- Al-Hajj, Samar; Ian Pike; Brian Fisher (2013). „Interactive dashboards: Using visual analytics for knowledge transfer and decision support“. In: *Proceedings of the 2013 Workshop on Visual Analytics in Healthcare, Washington, DC, USA*. Bd. 16.
- Hall, Mark (Juni 2000). „Correlation-Based Feature Selection for Machine Learning“. In: *Department of Computer Science* 19.
- Han, Ji-Hyeong; Su-Young Chi (2016). „Consideration of manufacturing data to apply machine learning methods for predictive manufacturing“. In: *2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN)*. IEEE, S. 109–113. ISBN: 978-1-4673-9991-3. DOI: 10.1109/ICUFN.2016.7536995.
- Han, Jiawei (2012). *Data mining: Concepts and techniques*. 3. Aufl. Morgan Kaufmann series in data management systems. Waltham: Morgan Kaufmann/Elsevier. ISBN: 978-0-12-381479-1.
- Hand, D. J.; Heikki Mannila; Padhraic Smyth (2001). *Principles of data mining*. A Bradford book. Cambridge und London: The MIT Press. ISBN: 9780262082907.

- Hao, Sihan; Sumei Li (2020). „A Weighted Mean Absolute Error Metric for Image Quality Assessment“. In: *2020 IEEE International Conference on Visual Communications and Image Processing (VCIP)*. IEEE, S. 330–333. ISBN: 978-1-7281-8068-7. DOI: 10.1109/VCIP49819.2020.9301889.
- Harby, Ahmed A.; Farhana Zulkernine (2022). „From Data Warehouse to Lakehouse: A Comparative Review“. In: *2022 IEEE International Conference on Big Data (Big Data)*. IEEE, S. 389–395. ISBN: 978-1-6654-8045-1. DOI: 10.1109/BigData55660.2022.10020719.
- Harris, Charles R.; K. Jarrod Millman; Stéfan J. van der Walt; Ralf Gommers; Pauli Virtanen; David Cournapeau; Eric Wieser; Julian Taylor; Sebastian Berg; Nathaniel J. Smith; Robert Kern; Matti Picus; Stephan Hoyer; Marten H. van Kerkwijk; Matthew Brett; Allan Haldane; Jaime Fernández Del Río; Mark Wiebe; Pearu Peterson; Pierre Gérard-Marchant; Kevin Sheppard; Tyler Reddy; Warren Weckesser; Hameer Abbasi; Christoph Gohlke; Travis E. Oliphant (2020). „Array programming with NumPy“. In: *Nature* 585.7825, S. 357–362. DOI: 10.1038/s41586-020-2649-2.
- Hartmann, Mark (2018). „Machine Learning und IT-Security“. In: *Datenschutz und Datensicherheit - DuD* 42.4, S. 231–235. DOI: 10.1007/s11623-018-0913-5.
- Harwardt, Mark (2022). *Management der digitalen Transformation*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-35917-1. DOI: 10.1007/978-3-658-35918-8.
- Harwardt, Mark; Maximilian Köhler (2023). *Künstliche Intelligenz entlang der Customer Journey*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-39108-9. DOI: 10.1007/978-3-658-39109-6.
- Hastie, Trevor; Robert Tibshirani; Jerome Friedman (2009). *The Elements of Statistical Learning*. New York: Springer New York. ISBN: 978-0-387-84857-0. DOI: 10.1007/978-0-387-84858-7.
- Hazen, Benjamin T.; Christopher A. Boone; Jeremy D. Ezell; L. Allison Jones-Farmer (2014). „Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications“. In: *International Journal of Production Economics* 154, S. 72–80. DOI: 10.1016/j.ijpe.2014.04.018.
- He, Kang; Minping Jia; Qingsong Xu (2016). „Optimal Sensor Deployment for Manufacturing Process Monitoring Based on Quantitative Cause-Effect Graph“. In: *IEEE Transactions on Automation Science and Engineering* 13.2, S. 963–975. DOI: 10.1109/TASE.2015.2430932.
- Heil, Benjamin J.; Michael M. Hoffman; Florian Markowetz; Su-In Lee; Casey S. Greene; Stephanie C. Hicks (2021). „Reproducibility standards for machine learning in the life sciences“. In: *Nature methods* 18.10, S. 1132–1135. DOI: 10.1038/s41592-021-01256-7.
- Helu, Moneer; Timothy Sprock; Daniel Hartenstine; Rishabh Venketesh; William Sobel (2020). „Scalable data pipeline architecture to support the industrial internet of things“. In: *CIRP Annals* 69.1, S. 385–388. DOI: 10.1016/j.cirp.2020.04.006.
- Hentschel, Raoul; Christian Leyh (2018). „Cloud Computing: Status quo, aktuelle Entwicklungen und Herausforderungen“. In: *Cloud Computing*. Hrsg. von Stefan Reinheimer.

- Edition HMD. Wiesbaden: Springer Fachmedien Wiesbaden, S. 3–20. ISBN: 978-3-658-20966-7. DOI: 10.1007/978-3-658-20967-4_1.
- Hesse, Stefan; Gerhard Schnell (2014). *Sensoren für die Prozess- und Fabrikautomation*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-05866-1. DOI: 10.1007/978-3-658-05867-8.
- Hevner, Alan; Samir Chatterjee (2010). „Design Science Research in Information Systems“. In: *Design Research in Information Systems*. Hrsg. von Alan Hevner; Samir Chatterjee. Bd. 22. Integrated Series in Information Systems. Boston: Springer US, S. 9–22. ISBN: 978-1-4419-5652-1. DOI: 10.1007/978-1-4419-5653-8_2.
- Hevner, Alan R. (2007). „A Three Cycle View of Design Science Research“. In: *Scandinavian Journal of Information Systems* 19.7, S. 87–92.
- Hevner; March; Park; Ram (2004). „Design Science in Information Systems Research“. In: *MIS Quarterly* 28.1, S. 75. DOI: 10.2307/25148625.
- Hewage, Nipuni; Dulani Meedeniya (2022). „Machine Learning Operations: A Survey on MLOps Tool Support“. In: DOI: 10.48550/arXiv.2202.10169.
- Hickman, Louis; Stuti Thapa; Louis Tay; Mengyang Cao; Padmini Srinivasan (2022). „Text Preprocessing for Text Mining in Organizational Research: Review and Recommendations“. In: *Organizational Research Methods* 25.1, S. 114–146. DOI: 10.1177/1094428120971683.
- Hirsch, Vitali; Peter Reimann; Bernhard Mitschang (2020). „Exploiting domain knowledge to address multi-class imbalance and a heterogeneous feature space in classification tasks for manufacturing data“. In: *Proceedings of the VLDB Endowment* 13.12, S. 3258–3271. DOI: 10.14778/3415478.3415549.
- Hitzler, Ronald (1994). „Wissen und Wesen des Experten“. In: *Expertenwissen*. Hrsg. von Ronald Hitzler; Anne Honer; Christoph Maeder. Wiesbaden: Vieweg+Teubner Verlag, S. 13–30. ISBN: 978-3-531-12581-7. DOI: 10.1007/978-3-322-90633-5_1.
- Hlupic, Tomislav; Drazen Orescanin; Domagoj Ruzak; Mirta Baranovic (2022). „An Overview of Current Data Lake Architecture Models“. In: *2022 45th Jubilee International Convention on Information, Communication and Electronic Technology (MIPRO)*. IEEE, S. 1082–1087. ISBN: 978-953-233-103-5. DOI: 10.23919/MIPRO55190.2022.9803717.
- Hodson, Timothy O.; Thomas M. Over; Sydney S. Foks (2021). „Mean Squared Error, Deconstructed“. In: *Journal of Advances in Modeling Earth Systems* 13.12. DOI: 10.1029/2021MS002681.
- Hofer, Andreas; Clemens Repp; Björn Klages (2020). „Strategisches Technologiemanagement in der Produktion“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 115.9, S. 559–562. DOI: 10.1515/zwf-2020-1150904.
- Hoffmann, H.; M. Kohnhäuser (2002). „Strategies to Optimize the Part Transport in Crossbar Transfer Presses“. In: *CIRP Annals* 51.1, S. 27–32. DOI: 10.1016/S0007-8506(07)61458-9.
- Holland, Heinrich (2020). „Big Data“. In: *Digitales Dialogmarketing*. Hrsg. von Heinrich Holland. Wiesbaden: Springer Fachmedien Wiesbaden, S. 1–23. ISBN: 978-3-658-28973-7. DOI: 10.1007/978-3-658-28973-7_10-1.

- Hoque, E.; M. Saidul Islam (2025). „Natural Language Generation for Visualizations: State of the Art, Challenges and Future Directions“. In: *Computer Graphics Forum* 44.1. DOI: 10.1111/cgf.15266.
- Horn, Eric van der; Zhenghua Wang; Sankaran Mahadevan (2022). „Towards a digital twin approach for vessel-specific fatigue damage monitoring and prognosis“. In: *Reliability Engineering & System Safety* 219, S. 108222. DOI: 10.1016/j.ress.2021.108222.
- Hosford, William F.; Robert M. Caddell (2012). *Metal Forming*. Cambridge University Press. ISBN: 9780521881210. DOI: 10.1017/CB09780511811111.
- Huber, Steffen; Hajo Wiemer; Dorothea Schneider; Steffen Ihlenfeldt (2019). „DMME: Data mining methodology for engineering applications – a holistic extension to the CRISP-DM model“. In: *Procedia CIRP* 79. 12th CIRP Conference on Intelligent Computation in Manufacturing Engineering, 18-20 July 2018, Gulf of Naples, Italy, S. 403–408. DOI: 10.1016/j.procir.2019.02.106.
- Huber, Walter (2016). *Industrie 4.0 in der Automobilproduktion*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-12731-2. DOI: 10.1007/978-3-658-12732-9.
- Hudetz, Walter; Michael Friedewald (2002). „Technische Produktdokumentation im Maschinen- und Anlagenbau“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 97.1-2, S. 64–68. DOI: 10.3139/104.100509.
- Hullman, Jessica; Nicholas Diakopoulos (2011). „Visualization rhetoric: framing effects in narrative visualization“. In: *IEEE transactions on visualization and computer graphics* 17.12, S. 2231–2240. DOI: 10.1109/TVCG.2011.255.
- Hurban, M; I Szendiuch (2018). „Digitalisation and networking in ‚smart production‘“. In: Iafrate, Fernando (2014). „A Journey from Big Data to Smart Data“. In: *Digital Enterprise Design & Management*. Hrsg. von Daniel Krob; Antoine Lonjon; Hervé Panetto; Pierre-Jean Benghozi. Bd. 261. SpringerLink Bücher. Cham: Springer International Publishing, S. 25–33. ISBN: 978-3-319-04313-5. DOI: 10.1007/978-3-319-04313-5_3.
- (2015). *From big data to smart data*. Bd. 1. Advanced in information systems set. London und Hoboken: ISTE und Wiley. ISBN: 978-1-84821-755-3.
- Iivari, Juhani (2007). „A Three Cycle View of Design Science Research“. In: *Scandinavian Journal of Information Systems* 19.7, S. 39–64.
- Im, Yerin; Mingyu Lim (2023). „E-MQTT: End-to-End Synchronous and Asynchronous Communication Mechanisms in MQTT Protocol“. In: *Applied Sciences* 13.22, S. 12419. DOI: 10.3390/app132212419.
- Inmon, William H. (2002). *Building the data warehouse*. 3. Aufl. Wiley computer publishing Timely, practical, reliable. New York und Weinheim: Wiley. ISBN: 0-471-08130-2. DOI: 2054.
- Ippolito, Massimo; Nikolaos Nikolakis; Tania Cerquitelli; Niamh O’Mahony; Sotirios Makris; Enrico Macii (2021). „Industrial Digitisation and Maintenance: Present and Future“. In: *Predictive Maintenance in Smart Factories*. Hrsg. von Tania Cerquitelli; Nikolaos Nikolakis; Niamh O’Mahony; Enrico Macii; Massimo Ippolito; Sotirios Makris. Information Fusion and Data Science. Singapore: Springer Singapore, S. 3–18. ISBN: 978-981-16-2939-6. DOI: 10.1007/978-981-16-2940-2_1.

- Jablonski, A.; T. Barszcz; M. Bielecka; P. Breuhaus (2013). „Modeling of probability distribution functions for automatic threshold calculation in condition monitoring systems“. In: *Measurement* 46.1, S. 727–738. DOI: 10.1016/j.measurement.2012.09.011.
- James, Gareth; Daniela Witten; Trevor Hastie; Robert Tibshirani; Jonathan Taylor (2023). „Linear Regression“. In: *An Introduction to Statistical Learning*. Hrsg. von Gareth James; Daniela Witten; Trevor Hastie; Robert Tibshirani; Jonathan Taylor. Springer Texts in Statistics. Cham: Springer International Publishing, S. 69–134. ISBN: 978-3-031-38746-3. DOI: 10.1007/978-3-031-38747-0_3.
- Janelidze, Gulnara; Ia Aptsiauri; Lela Tsitashvili (2024). „Data lakes: Opportunities, Challenges, Threats and Ways to Mitigate Them“. In: *Journal of Technical Science and Technologies* 8.2, S. 31–35. DOI: 10.31578/jtst.v8i2.159.
- Janes, Andrea; Alberto Sillitti; Giancarlo Succi et al. (2013). „Effective dashboard design“. In: *Cutter IT journal* 26.1, S. 17–24.
- Jankovič, Denis; Marko Šimic; Niko Heraković (2021). „The Concept of Smart Hydraulic Press“. In: *Service Oriented, Holonic and Multi-Agent Manufacturing Systems for Industry of the Future*. Hrsg. von Theodor Borangiu; Damien Trentesaux; Paulo Leitão; Olivier Cardin; Samir Lamouri. Bd. 952. Studies in Computational Intelligence. Cham: Springer International Publishing, S. 409–420. ISBN: 978-3-030-69372-5. DOI: 10.1007/978-3-030-69373-2_29.
- Janssen, Nathalie; Tharaka Ilayperuma; Jeewanie Jayasinghe; Faiza Bukhsh; Maya Daneva (2024). „The evolution of data storage architectures: examining the secure value of the Data Lakehouse“. In: *Journal of Data, Information and Management* 6.4, S. 309–334. DOI: 10.1007/s42488-024-00132-1.
- Jardine, Andrew K.S.; Daming Lin; Dragan Banjevic (2006). „A review on machinery diagnostics and prognostics implementing condition-based maintenance“. In: *Mechanical Systems and Signal Processing* 20.7, S. 1483–1510. DOI: 10.1016/j.ymssp.2005.09.012.
- Jarke, Matthias (2003). *Fundamentals of Data Warehouses*. 1. Aufl. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 9783662051535.
- Järvinen, Pertti (2007). „Action Research is Similar to Design Science“. In: *Quality & Quantity* 41.1, S. 37–54. DOI: 10.1007/s11135-005-5427-1.
- Javidan, Seyed Mohamad; Ahmad Banakar; Kamran Rahnema; Keyvan Asefpour Vakilian; Yiannis Ampatzidis (2024). „Feature engineering to identify plant diseases using image processing and artificial intelligence: A comprehensive review“. In: *Smart Agricultural Technology* 8, S. 100480. DOI: 10.1016/j.atech.2024.100480.
- Jericho, Tom (2022). „Data Science in press shop – Using machine learning algorithms to predict downtime“. Unveröffentlichte Masterarbeit in Kooperation mit der Volkswagen AG; fachliche Betreuung im Unternehmen: Safa Evirgen. Masterarbeit. Aachen: RWTH Aachen University, Institute for Data Science in Mechanical Engineering.
- Jeswiet, J.; M. Geiger; U. Engel; M. Kleiner; M. Schikorra; J. Dufflou; R. Neugebauer; P. Bariani; S. Bruschi (2008). „Metal forming progress since 2000“. In: *CIRP Journal of Manufacturing Science and Technology* 1.1, S. 2–17. DOI: 10.1016/j.cirpj.2008.06.005.

- Jin, Jionghua; Jianjun Shi (2005). „Press Tonnage Signal Decomposition and Validation Analysis for Transfer or Progressive Die Processes“. In: *Journal of Manufacturing Science and Engineering* 127.1, S. 231–235. DOI: 10.1115/1.1831287.
- Johansson, Robert (2015). *Numerical Python*. Berkeley: Apress. ISBN: 978-1-4842-0554-9. DOI: 10.1007/978-1-4842-0553-2.
- Jourdan, Nicolas; Tom Bayer; Tobias Biegel; Joachim Metternich (2023). „Handling concept drift in deep learning applications for process monitoring“. In: *Procedia CIRP* 120, S. 33–38. DOI: 10.1016/j.procir.2023.08.007.
- Juhl, Dietrich (2015). *Technische Dokumentation*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-46864-7. DOI: 10.1007/978-3-662-46865-4.
- Jutadhamakorn, Pongnapat; Tinnapat Pillavas; Vasaka Visoottiviseth; Ryousei Takano; Jason Haga; Dylan Kobayashi (2017). „A scalable and low-cost MQTT broker clustering system“. In: *2017 2nd International Conference on Information Technology (INCIT)*. IEEE, S. 1–5. ISBN: 978-1-5386-1431-0. DOI: 10.1109/INCIT.2017.8257870.
- Kammerer, Klaus; Rüdiger Pryss; Burkhard Hoppenstedt; Kevin Sommer; Manfred Reichert (2020). „Process-Driven and Flow-Based Processing of Industrial Sensor Data“. In: *Sensors (Basel, Switzerland)* 20.18. DOI: 10.3390/s20185245.
- Kanawaday, Ameeth; Aditya Sane (2017). „Machine learning for predictive maintenance of industrial machines using IoT sensor data“. In: *2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. IEEE, S. 87–90. ISBN: 978-1-5386-0497-7. DOI: 10.1109/ICSESS.2017.8342870.
- Kanda, Hisashi; Hiroyuki Okamura; Tadashi Dohi (2023). „A Note on Optimal Retraining Strategy for ML Systems“. In: *2023 10th International Conference on Dependable Systems and Their Applications (DSA)*. IEEE, S. 730–733. ISBN: 979-8-3503-0477-0. DOI: 10.1109/DSA59317.2023.00104.
- Karamitsos, Ioannis; Saeed Albarhami; Charalampos Apostolopoulos (2020). „Applying DevOps Practices of Continuous Automation for Machine Learning“. In: *Information* 11.7. DOI: 10.3390/info11070363.
- Katari, Abhilash (2023). „Security and Governance in Financial Data Lakes: Challenges and Solutions“. In: *Journal of Computational Innovation* 3.1.
- Kateris, Dimitrios; Dimitrios Moshou; Xanthoula-Eirini Pantazi; Ioannis Gravalos; Nader Sawalhi; Spiros Loutridis (2014). „A machine learning approach for the condition monitoring of rotating machinery“. In: *Journal of Mechanical Science and Technology* 28.1, S. 61–71. DOI: 10.1007/s12206-013-1102-y.
- Kauermann, Göran (2020). „Data Science – Einige Gedanken aus Sicht eines Statistikers“. In: *Informatik Spektrum* 42.6, S. 387–393. DOI: 10.1007/s00287-019-01224-8.
- Kelleher, John D.; Brian Mac Namee; Aoife D’Arcy (2020). *Fundamentals of machine learning for predictive data analytics: Algorithms, worked examples, and case studies*. 2. Aufl. The MIT Press Ser. Cambridge: The MIT Press. ISBN: 9780262364911.
- Kesavaraaj, G.; S. Sukumaran (2013). „A study on classification techniques in data mining“. In: *2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*. IEEE, S. 1–7. ISBN: 978-1-4799-3926-8. DOI: 10.1109/ICCCNT.2013.6726842.

- Ketokivi, Mikko (2006). „Elaborating the Contingency Theory of Organizations: The Case of Manufacturing Flexibility Strategies“. In: *Production and Operations Management* 15.2, S. 215–228. DOI: 10.1111/j.1937-5956.2006.tb00241.x.
- Khalid, Samina; Tehmina Khalil; Shamila Nasreen (2014). „A survey of feature selection and feature extraction techniques in machine learning“. In: *2014 Science and Information Conference*. IEEE, S. 372–378. ISBN: 978-0-9893193-1-7. DOI: 10.1109/SAI.2014.6918213.
- Khine, Pwint Phyu; Zhao Shun Wang (2018). „Data lake: a new ideology in big data era“. In: *ITM Web of Conferences* 17, S. 03025. DOI: 10.1051/itmconf/20181703025.
- Kim, Rockwon; Su-Young Chi; Wan C. Yoon (2016). „Data integration and arrangement in the shop floor based-on time stamp: An illustrative study of CNC machining“. In: *2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN)*. IEEE, S. 121–124. ISBN: 978-1-4673-9991-3. DOI: 10.1109/ICUFN.2016.7536998.
- Kim, Sang-Bum; Kyoung-Soo Han; Hae-Chang Rim; Sung Hyon Myaeng (2006). „Some Effective Techniques for Naive Bayes Text Classification“. In: *IEEE Transactions on Knowledge and Data Engineering* 18.11, S. 1457–1466. DOI: 10.1109/TKDE.2006.180.
- Kimball, Ralph; Margy Ross (2002). *The data warehouse toolkit: The complete guide to dimensional modeling*. 2. Aufl. New York und Weinheim: Wiley. ISBN: 0-471-20024-7.
- (2013). *The data warehouse toolkit: The definitive guide to dimensional modeling*. 3. Aufl. Indianapolis: Wiley. ISBN: 978-1-118-53080-1.
- Kirasich, Kaitlin; Trace Smith; Bivin Sadler (2018). „Random forest vs logistic regression: binary classification for heterogeneous datasets“. In: *SMU Data Science Review* 1.3.
- Klees, Marina; Safa Evirgen (2022). „Building a smart database for predictive maintenance in already implemented manufacturing systems“. In: *Procedia Computer Science* 204, S. 14–21. DOI: 10.1016/j.procs.2022.08.002.
- Klein, Heinz K.; Michael D. Myers (1999). „A Set of Principles for Conducting and Evaluating Interpretive Field Studies in Information Systems“. In: *MIS Quarterly* 23.1, S. 67. DOI: 10.2307/249410.
- Klein, Patrick; Lukas Malburg; Ralph Bergmann (2025). „Combining informed data-driven anomaly detection with knowledge graphs for root cause analysis in predictive maintenance“. In: *Engineering Applications of Artificial Intelligence* 145, S. 110152. DOI: 10.1016/j.engappai.2025.110152.
- Knoblauch, Jonathan; Rebecca Bulander; Thomas Greiner (2015). „Development of an Anything Relationship Management Prototype for the Smart Factory“. In: *Proceedings of the 5th International Conference on Cloud Computing and Services Science*. SCITEPRESS - Science and Technology Publications, S. 127–134. ISBN: 978-989-758-104-5. DOI: 10.5220/0005444601270134.
- Knuth, Tobias (2021). „Lernende Entscheidungsbäume“. In: *Informatik Spektrum* 44.5, S. 364–369. DOI: 10.1007/s00287-021-01398-0.
- Kohl, Arno (2011). *ActionScript 2*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-540-35179-5. DOI: 10.1007/978-3-540-35182-5.
- Kohl, Linus; Fazel Ansari; Wilfried Sihm (2021). „A Modular Federated Learning Architecture for Integration of AI-enhanced Assistance in Industrial Maintenance - A novel

- architecture for enhancing industrial maintenance management systems in the automotive and semiconductor industry“. In: *Competence development and learning assistance systems for the data-driven future*. Hrsg. von Wilfried Sihm; Sebastian Schlund. Goto Verlag, S. 229–242. ISBN: 9783955453961. DOI: 10.30844/wgab_2021_14.
- Kohn, Wolfgang (2005). „Eindimensionale Datenanalyse“. In: *Statistik: Datenanalyse und Wahrscheinlichkeitsrechnung*, S. 35–100.
- Kolerus, Josef; Edwin Becker (2022). *Condition Monitoring und Instandhaltungsmanagement*. expert verlag. ISBN: 9783816984894. DOI: 10.24053/9783816984894.
- Kolerus, Josef; Johann Wassermann (2017). *Zustandsüberwachung von Maschinen: Das Lehr- und Arbeitsbuch für den Praktiker*. 7. Aufl. Bd. 5181. utb-studi-e-book. Stuttgart und Konstanz: UTB GmbH und UVK. ISBN: 978-3-8385-5181-4.
- Konzack, Maximilian; Pieter Gijbbers; Ferry Timmers; Emiel van Loon; Michel A. Westenberg; Kevin Buchin (2019). „Visual exploration of migration patterns in gull data“. In: *Information Visualization* 18.1, S. 138–152. DOI: 10.1177/1473871617751245.
- Kopenhagen, Norbert; Oliver Gaß; Benjamin Müller (2012). „Design Science Research in Action - Anatomy of Success Critical Activities for Rigor and Relevance“. In: DOI: 10.5445/IR/1000055012.
- Kothes, Lars (2011). *Grundlagen der Technischen Dokumentation*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-642-14667-1. DOI: 10.1007/978-3-642-14668-8.
- Kreutzer, Ralf T.; Marie Sirrenberg (2019). *Künstliche Intelligenz verstehen*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-25560-2. DOI: 10.1007/978-3-658-25561-9.
- Kreuzberger, Dominik; Niklas Kühl; Sebastian Hirschl (2023). „Machine Learning Operations (MLOps): Overview, Definition, and Architecture“. In: *IEEE Access* 11, S. 31866–31879. DOI: 10.1109/ACCESS.2023.3262138.
- Krichen, Moez (2023). „Convolutional Neural Networks: A Survey“. In: *Computers* 12.8, S. 151. DOI: 10.3390/computers12080151.
- Krishna Menon, Madhu; Rabin Tuladhar (2024). „Asset Management decision-making through data-driven Predictive Maintenance – an overview, techniques, benefits and challenges“. In: *Maintenance, Reliability and Condition Monitoring* 4.2, S. 44–63. DOI: 10.21595/marc.2024.24232.
- Kropik, Markus (2009). *Produktionsleitsysteme in der Automobilfertigung*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-540-88990-8. DOI: 10.1007/978-3-540-88991-5.
- (2021). *Produktionsleitsysteme für die Automobilindustrie: Digitalisierung des Shop-Floors in der Automobilproduktion*. 2. Aufl. Berlin: Springer Berlin und Springer Vieweg. ISBN: 9783662622261.
- Kropshofer, Jasmin; Johannes Schrott; Wolfram Wöß; Lisa Ehrlinger (2025). „A Survey on the Functionalities of Data Catalog Tools“. In: *IEEE Access* 13, S. 83297–83319. DOI: 10.1109/ACCESS.2025.3568542.

- Krupitzer, Christian; Tim Wagenhals; Marwin Züfle; Veronika Lesch; Dominik Schäfer; Amin Mozaffarin; Janick Edinger; Christian Becker; Samuel Kounev (2020). „A Survey on Predictive Maintenance for Industry 4.0“. In: DOI: 10.48550/arXiv.2002.08224.
- Kuckartz, Udo (2018). *Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung*. 4. Aufl. Grundlagentexte Methoden. Weinheim: Beltz. ISBN: 9783779946830.
- Kuhn, Max; Kjell Johnson (2020). *Feature engineering and selection: A practical approach for predictive models*. Chapman & Hall/CRC data science series. Boca Raton, London und New York: CRC Press Taylor & Francis Group. ISBN: 978-1-138-07922-9.
- Kulesza, Todd; Saleema Amershi; Rich Caruana; Danyel Fisher; Denis Charles (2014). „Structured labeling for facilitating concept evolution in machine learning“. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. Hrsg. von Matt Jones; Philippe Palanque; Albrecht Schmidt; Tovi Grossman. New York: ACM, S. 3075–3084. ISBN: 9781450324731. DOI: 10.1145/2556288.2557238.
- Kumar, Apurva; Shilpa Priyadarshini (2025). „Adaptive AI Infrastructure: A Containerized Approach for Scalable Model Deployment“. In: *International Research Journal of Modernization in Engineering Technology and Science*. DOI: 10.56726/IRJMETS64700.
- Kumar, Subhashish; Namrata Dhanda; Ashutosh Pandey (2018). „Data Science — Cosmic Infoset Mining, Modeling and Visualization“. In: *2018 International Conference on Computational and Characterization Techniques in Engineering & Sciences (CCTES)*. IEEE, S. 1–4. ISBN: 978-1-5386-4254-2. DOI: 10.1109/CCTES.2018.8674138.
- Laaksonen, J.; E. Oja (1996). „Classification with learning k-nearest neighbors“. In: *Proceedings of International Conference on Neural Networks (ICNN'96)*. IEEE, S. 1480–1483. ISBN: 0-7803-3210-5. DOI: 10.1109/ICNN.1996.549118.
- Lamnek, Siegfried; Claudia Krell (2016). *Qualitative Sozialforschung: Mit Online-Materialien*. 6. Aufl. Weinheim: Beltz. ISBN: 9783621283625.
- Lapin, Maksim; Matthias Hein; Bernt Schiele (2018). „Analysis and Optimization of Loss Functions for Multiclass, Top-k, and Multilabel Classification“. In: *IEEE transactions on pattern analysis and machine intelligence* 40.7, S. 1533–1554. DOI: 10.1109/TPAMI.2017.2751607.
- Latyshev, Evgeniy (2018). „Sensor Data Preprocessing, Feature Engineering and Equipment Remaining Lifetime Forecasting for Predictive Maintenance“. In: *International Conference on Data Analytics and Management in Data Intensive Domains*. URL: <https://api.semanticscholar.org/CorpusID:58005342>.
- LaValley, Michael P. (2008). „Logistic regression“. In: *Circulation* 117.18, S. 2395–2399. DOI: 10.1161/CIRCULATIONAHA.106.682658.
- Lazakis, Iraklis; Konstantinos Dikis; Anna Lito Michala; Gerasimos Theotokatos (2016). „Advanced Ship Systems Condition Monitoring for Enhanced Inspection, Maintenance and Decision Making in Ship Operations“. In: *Transportation Research Procedia* 14, S. 1679–1688. DOI: 10.1016/j.trpro.2016.05.133.
- Lee, Jay; Jun Ni; Jaskaran Singh; Baoyang Jiang; Moslem Azamfar; Jianshe Feng (2020). „Intelligent Maintenance Systems and Predictive Manufacturing“. In: *Journal of Manufacturing Science and Engineering* 142.11. DOI: 10.1115/1.4047856.

- Lee, Wookey; Carson K. Leung; Aziz Nasridinov (2021). *Big Data Analyses, Services, and Smart Data*. Bd. 899. Singapore: Springer Singapore. ISBN: 978-981-15-8730-6. DOI: 10.1007/978-981-15-8731-3.
- Leidinger, Bernhard (2017). *Wertorientierte Instandhaltung: Kosten senken, Verfügbarkeit erhalten*. 2. Aufl. Wiesbaden und Heidelberg: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-17854-3. DOI: 10.1007/978-3-658-17855-0.
- Lettner, Christian; Reinhard Stumptner; Karl-Heinz Bokesch (2014). „An Approach on ETL Attached Data Quality Management“. In: *Data Warehousing and Knowledge Discovery*. Hrsg. von Ladjel Bellatreche; Mukesh K. Mohania. Bd. 8646. Lecture Notes in Computer Science. Cham: Springer International Publishing, S. 1–8. ISBN: 978-3-319-10159-0. DOI: 10.1007/978-3-319-10160-6_1.
- Levin, Esther (1990). „A recurrent neural network: Limitations and training“. In: *Neural Networks* 3.6, S. 641–650. DOI: 10.1016/0893-6080(90)90054-0.
- Li, Chaoqun; Liangxiao Jiang; Hongwei Li (2014). „Naive Bayes for value difference metric“. In: *Frontiers of Computer Science* 8.2, S. 255–264. DOI: 10.1007/s11704-014-3038-5.
- Li, Zewen; Fan Liu; Wenjie Yang; Shouheng Peng; Jun Zhou (2022). „A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects“. In: *IEEE transactions on neural networks and learning systems* 33.12, S. 6999–7019. DOI: 10.1109/TNNLS.2021.3084827.
- Likas, Aristidis; Nikos Vlassis; Jakob J. Verbeek (2003). „The global k-means clustering algorithm“. In: *Pattern Recognition* 36.2, S. 451–461. DOI: 10.1016/S0031-3203(02)00060-2.
- Lillicrap, Timothy P.; Adam Santoro; Luke Marris; Colin J. Akerman; Geoffrey Hinton (2020). „Backpropagation and the brain“. In: *Nature reviews. Neuroscience* 21.6, S. 335–346. DOI: 10.1038/s41583-020-0277-3.
- Liu, Shaofeng; Boris Delibasic; Lynne Butel; Xue Han (2017). „Sustainable knowledge-based decision support systems (DSS): perspectives, new challenges and recent advance“. In: *Industrial Management & Data Systems* 117.7, S. 1318–1322. DOI: 10.1108/IMDS-04-2017-0137.
- Löcklin, Andreas; Tobias Jung; Nasser Jazdi; Tamás Ruppert; Michael Weyrich (2021). „Architecture of a Human-Digital Twin as Common Interface for Operator 4.0 Applications“. In: *Procedia CIRP* 104, S. 458–463. DOI: 10.1016/j.procir.2021.11.077.
- López-Meneses, Eloy; Luis López-Catalán; Noelia Pelicano-Piris; Pedro C. Mellado-Moreno (2025). „Artificial Intelligence in Educational Data Mining and Human-in-the-Loop Machine Learning and Machine Teaching: Analysis of Scientific Knowledge“. In: *Applied Sciences* 15.2. DOI: 10.3390/app15020772.
- Lu, Jiaheng; Zhen Hua Liu; Pengfei Xu; Chao Zhang (2018). „UDBMS: Road to Unification for Multi-model Data Management“. In: *Advances in Conceptual Modeling*. Hrsg. von Carson Woo; Jiaheng Lu; Zhanhuai Li; Tok Wang Ling; Guoliang Li; Mong Li Lee. Bd. 11158. Lecture Notes in Computer Science. Cham: Springer International Publishing, S. 285–294. ISBN: 978-3-030-01390-5. DOI: 10.1007/978-3-030-01391-2_33.
- Luengo, Julián; Diego García-Gil; Sergio Ramírez-Gallego; Salvador García; Francisco Herrera (2020). „Introduction“. In: *Big Data Preprocessing*. Hrsg. von Julián Luengo; Diego

- García-Gil; Sergio Ramírez-Gallego; Salvador García; Francisco Herrera. Cham: Springer International Publishing, S. 1–14. ISBN: 978-3-030-39104-1. DOI: 10.1007/978-3-030-39105-8_1.
- Lunze, Jan (2010). „Strukturelle Beschreibung dynamischer Systeme“. In: *Regelungstechnik* 1. Hrsg. von Jan Lunze. Springer-Lehrbuch. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 39–53. ISBN: 978-3-642-13807-2. DOI: 10.1007/978-3-642-13808-9_3.
- Luo, Gang (2016). „A review of automatic selection methods for machine learning algorithms and hyper-parameter values“. In: *Network Modeling Analysis in Health Informatics and Bioinformatics* 5.1. DOI: 10.1007/s13721-016-0125-6.
- Madera, Cedrine; Anne Laurent (2016). „The next information architecture evolution“. In: *Proceedings of the 8th International Conference on Management of Digital EcoSystems*. Hrsg. von Richard Chbeir; Rajeev Agrawal; Ismail Biskri. New York: ACM, S. 174–180. ISBN: 9781450342674. DOI: 10.1145/3012071.3012077.
- Mahadevan, Ananth; Michael Mathioudakis (2023). „Cost-Effective Retraining of Machine Learning Models“. In: DOI: 10.48550/arXiv.2310.04216.
- Mahida, Ankur (2021). „A Review on Continuous Integration and Continuous Deployment (CI/CD) for Machine Learning“. In: *International Journal of Science and Research (IJSR)* 10.3, S. 1967–1970. DOI: 10.21275/SR24314131827.
- Mahsereci, Maren; Lukas Balles; Christoph Lassner; Philipp Hennig (2017). „Early Stopping without a Validation Set“. In: DOI: 10.48550/arXiv.1703.09580.
- Maksood, Fathimath Zuha; Geetha Achuthan (o. D.). „Analysis of data mining techniques and its applications“. In: *International Journal of Computer Applications* 140.3 (), S. 6–14.
- Mallick, Ankur; Kevin Hsieh; Behnaz Arzani; Gauri Joshi (2022). „Matchmaker: Data Drift Mitigation in Machine Learning for Large-Scale Systems“. In: *Proceedings of Machine Learning and Systems*. Hrsg. von D. Marculescu; Y. Chi; C. Wu. Bd. 4, S. 77–94. URL: https://proceedings.mlsys.org/paper_files/paper/2022/file/069a002768bcb31509d4901961f23b3c-Paper.pdf.
- Mallioris, Panagiotis; Eirini Aivazidou; Dimitrios Bechtsis (2024). „Predictive maintenance in Industry 4.0: A systematic multi-sector mapping“. In: *CIRP Journal of Manufacturing Science and Technology* 50, S. 80–103. DOI: 10.1016/j.cirpj.2024.02.003.
- Mallioris, Panagiotis; Charalampos Polychroniadis; Antonios Moustakas; Nikolaos Mitakidis; Dimitrios Bechtsis (2025). *Holistic Maintenance Framework for Predictive and Prescriptive Maintenance in Industry 4.0 Using Artificial Intelligence and Natural Language Processing*. DOI: 10.2139/ssrn.5216697.
- Mammone, Alessia; Marco Turchi; Nello Cristianini (2009). „Support vector machines“. In: *WIREs Computational Statistics* 1.3, S. 283–289. DOI: <https://doi.org/10.1002/wics.49>.
- Manchana, Ramakrishna (2022). „Building a Modern Data Foundation in the Cloud: Data Lakes and Data Lakehouses as Key Enablers“. In: *Journal of Artificial Intelligence, Machine Learning and Data Science* 1.1, S. 1098–1108. DOI: 10.51219/JAIMLD/Ramakrishna-manchana/260.

- Manning, Christopher D.; Prabhakar Raghavan; Hinrich Schütze (2008). *Introduction to information retrieval*. Cambridge: Cambridge University Press. ISBN: 978-0-511-41405-3.
- Mao, Haoyang; Zhenyu Liu; Chan Qiu; Yu Huang; Jianrong Tan (2023). „Prescriptive maintenance for complex products with digital twin considering production planning and resource constraints“. In: *Measurement Science and Technology* 34.12, S. 125903. DOI: 10.1088/1361-6501/aced5f.
- March, Salvatore T.; Gerald F. Smith (1995). „Design and natural science research on information technology“. In: *Decision Support Systems* 15.4, S. 251–266. DOI: 10.1016/0167-9236(94)00041-2.
- Marcondes, Diego; Adilson Simonis; Junior Barrera (2020). „Learning the Hypotheses Space from data“. In: *arXiv*.
- Marsland, Stephen (2011). *Machine Learning*. Chapman and Hall/CRC. ISBN: 9781420067194. DOI: 10.1201/9781420067194.
- Martinez, Wendy L.; Angel R. Martinez; Jeffrey L. Solka (2017). *Exploratory data analysis with MATLAB*. 3. Aufl. Chapman & Hall/CRC computer science and data analysis series. Boca Raton, London und New York: CRC Press Taylor & Francis Group. ISBN: 978-1-4987-7606-6.
- Massaro, Alessandro; Sergio Selicato; Roberto Miraglia; Antonio Panarese; Angelo Calicchio; Angelo Galiano (2020). „Production Optimization Monitoring System Implementing Artificial Intelligence and Big Data“. In: *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*. IEEE, S. 570–575. ISBN: 978-1-7281-4892-2. DOI: 10.1109/MetroInd4.0IoT48571.2020.9138198.
- Matook, Sabine; Marta Indulska (2009). „Improving the quality of process reference models: A quality function deployment-based approach“. In: *Decision Support Systems* 47.1, S. 60–71. DOI: 10.1016/j.dss.2008.12.006.
- Matwin, Stan; Shipeng Yu; Faisal Farooq, Hrsg. (2017). *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM. ISBN: 9781450348874. DOI: 10.1145/3097983.
- Matyas, Kurt (2019). *Instandhaltungslogistik: Qualität und Produktivität steigern*. 7. Aufl. Praxisreihe Qualität. München: Hanser. ISBN: 9783446457621.
- Matyas, Kurt; Tanja Nemeth; Klaudia Kovacs; Robert Glawar (2017). „A procedural approach for realizing prescriptive maintenance planning in manufacturing industries“. In: *CIRP Annals* 66.1, S. 461–464. DOI: 10.1016/j.cirp.2017.04.007.
- Mazumdar, Dipankar; Jason Hughes; J. B. Onofre (2023). „The Data Lakehouse: Data Warehousing and More“. In: DOI: 10.48550/arXiv.2310.08697.
- McCarthy, John; Marvin L. Minsky; Nathaniel Rochester; Claude E. Shannon (2006). „A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955“. In: *AI Magazine* 27.4. DOI: 10.1609/aimag.v27i4.1904.
- McElroy, Mark W. (2010). *The New Knowledge Management*. Routledge. DOI: 10.4324/9780080512655.
- McKinney, Wes (2022). *Python for Data Analysis*. 3. Aufl. Safari, an O'Reilly Media Company. ISBN: 978-1098104030.

- Mehdiyev, Nijat; Johannes Lahann; Andreas Emrich; David Enke; Peter Fettke; Peter Loos (2017). „Time Series Classification using Deep Learning for Process Planning: A Case from the Process Industry“. In: *Procedia Computer Science* 114, S. 242–249. DOI: 10.1016/j.procs.2017.09.066.
- Mehmood, Erum; Tayyaba Anees (2022). „Distributed real-time ETL architecture for unstructured big data“. In: *Knowledge and Information Systems* 64.12, S. 3419–3445. DOI: 10.1007/s10115-022-01757-7.
- Mehmood, Hassan; Ekaterina Gilman; Marta Cortes; Panos Kostakos; Andrew Byrne; Katerina Valta; Stavros Tekes; Jukka Riekk (2019). „Implementing Big Data Lake for Heterogeneous Data Sources“. In: *2019 IEEE 35th International Conference on Data Engineering Workshops (ICDEW)*. IEEE, S. 37–44. ISBN: 978-1-7281-0890-2. DOI: 10.1109/ICDEW.2019.00-37.
- Mehta, Rachna; Navneet Agrawal (2018). „The Impact of Picture Splicing Operation for Picture Forgery Detection“. In: *Advances in Computing and Data Sciences*. Hrsg. von Mayank Singh; P. K. Gupta; Vipin Tyagi; Jan Flusser; Tuncer Ören. Bd. 905. Communications in Computer and Information Science. Singapore: Springer Singapore, S. 290–301. ISBN: 978-981-13-1809-2. DOI: 10.1007/978-981-13-1810-8_29.
- Mende, Leonie (2020). „Merkmalentstehungs- und -wechselwirkungsanalyse (MEWA) für das prozessorientierte Toleranzmanagement in der Montage“. Diss. DOI: 10.22028/D291-32507.
- Merklein, M.; J. M. Allwood; B.-A. Behrens; A. Brosius; H. Hagenah; K. Kuzman; K. Mori; A. E. Tekkaya; A. Weckenmann (2012). „Bulk forming of sheet metal“. In: *CIRP Annals* 61.2, S. 725–745. DOI: 10.1016/j.cirp.2012.05.007.
- Merten, Peter P. (1991). „Loop-based strategic decision support systems“. In: *Strategic Management Journal* 12.5, S. 371–386. DOI: 10.1002/smj.4250120504.
- Merton, Robert K. (1968). *Social theory and social structure*. New York: The free press. ISBN: 978-0029211304.
- Miao, Jiaju; Wei Zhu (2022). „Precision–recall curve (PRC) classification trees“. In: *Evolutionary Intelligence* 15.3, S. 1545–1569. DOI: 10.1007/s12065-021-00565-2.
- Milanowski, Dimitrios; Georgios Galanopoulos; Dimitrios Zarouchas; Theodoros Loutas (2023). „Multi-level damage diagnosis on stiffened composite panels based on a damage-uninformative digital twin“. In: *Structural Health Monitoring* 22.2, S. 1437–1459. DOI: 10.1177/14759217221108676.
- Miller, Kyle; Artur Dubrawski (2020). „System-Level Predictive Maintenance: Review of Research Literature and Gap Analysis“. In: DOI: 10.48550/arXiv.2005.05239.
- Milo, Tova; Amit Somech (2020). „Automating Exploratory Data Analysis via Machine Learning: An Overview“. In: *Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data*. Hrsg. von David Maier; Rachel Pottinger; AnHai Doan; Wang-Chiew Tan; Abdussalam Alawini; Hung Q. Ngo. New York: ACM, S. 2617–2622. ISBN: 9781450367356. DOI: 10.1145/3318464.3383126.
- Minh, Dang; H. Xiang Wang; Y. Fen Li; Tan N. Nguyen (2022). „Explainable artificial intelligence: a comprehensive review“. In: *Artificial Intelligence Review* 55.5, S. 3503–3568. DOI: 10.1007/s10462-021-10088-y.

- Mintzberg, Henry (1979). „An Emerging Strategy of Direct Research“. In: *Administrative Science Quarterly* 24.4, S. 582. DOI: 10.2307/2392364.
- Mitchell, Thomas M. (1997). *Machine learning*. Singapore: McGraw-Hill. ISBN: 0070428077.
- Mitchell, Tom M. (2010). *Machine learning*. McGraw-Hill series in computer science. New York: McGraw-Hill. ISBN: 0070428077.
- Mobley, R. Keith (2002). *An introduction to predictive maintenance*. 2. Aufl. Amsterdam: Butterworth-Heinemann. ISBN: 978-0-7506-7531-4.
- Mockenhaupt, Andreas (2021). „Digitalisierung und KI in der Produktion“. In: *Digitalisierung und Künstliche Intelligenz in der Produktion*. Hrsg. von Andreas Mockenhaupt. Wiesbaden: Springer Fachmedien Wiesbaden, S. 227–269. ISBN: 978-3-658-32772-9. DOI: 10.1007/978-3-658-32773-6_10.
- Mohamed, Nader; Jameela Al-Jaroodi; Sanja Lazarova-Molnar (2019). „Leveraging the Capabilities of Industry 4.0 for Improving Energy Efficiency in Smart Factories“. In: *IEEE Access* 7, S. 18008–18020. DOI: 10.1109/ACCESS.2019.2897045.
- Mohammadi, Mobin; Vahid Esfahanian (2025). „A comprehensive investigation to enhance predictive accuracy of data-driven models applied to air-cooled condensers: from domain expertise data preprocessing to hyperparameters optimization“. In: *Applied Thermal Engineering* 267, S. 125792. DOI: 10.1016/j.applthermaleng.2025.125792.
- Mohanty, Amiya R. (2015). *Machinery condition monitoring: Principles and practices*. 1. Aufl. Boca Raton: CRC Press. ISBN: 9781351228626.
- Monica; Parul Agrawal (2024). „A Survey on Hyperparameter Optimization of Machine Learning Models“. In: *2024 2nd International Conference on Disruptive Technologies (ICDT)*. IEEE, S. 11–15. ISBN: 979-8-3503-7105-5. DOI: 10.1109/ICDT61202.2024.10489732.
- Morato, Alberto; Stefano Vitturi; Federico Tramarin; Angelo Cenedese (2021). „Assessment of Different OPC UA Implementations for Industrial IoT-Based Measurement Applications“. In: *IEEE Transactions on Instrumentation and Measurement* 70, S. 1–11. DOI: 10.1109/TIM.2020.3043116.
- Morselli, Filippo; Luca Bedogni; Umberto Mirani; Michele Fantoni; Simone Galasso (2021). „Anomaly Detection and Classification in Predictive Maintenance Tasks with Zero Initial Training“. In: *IoT* 2.4, S. 590–609. DOI: 10.3390/iot2040030.
- Mosqueira-Rey, Eduardo; Elena Hernández-Pereira; David Alonso-Ríos; José Bobes-Bascarán; Ángel Fernández-Leal (2023). „Human-in-the-loop machine learning: a state of the art“. In: *Artificial Intelligence Review* 56.4, S. 3005–3054. DOI: 10.1007/s10462-022-10246-w.
- Mucherino, Antonio; Petraq J. Papajorgji; Panos M. Pardalos (2009). „k-Nearest Neighbor Classification“. In: *Data Mining in Agriculture*. Hrsg. von Antonio Mucherino; Petraq J. Papajorgji; Panos M. Pardalos. Bd. 34. Springer Optimization and Its Applications. New York: Springer New York, S. 83–106. ISBN: 978-0-387-88614-5. DOI: 10.1007/978-0-387-88615-2_4.
- Mucksch, Harry; Wolfgang Behme (2000). „Das Data Warehouse-Konzept als Basis einer unternehmensweiten Informationslogistik“. In: *Das Data Warehouse-Konzept*. Hrsg. von

- Harry Mucksch; Wolfgang Behme. Wiesbaden: Gabler Verlag, S. 3–80. ISBN: 978-3-409-42216-1. DOI: 10.1007/978-3-322-89533-2_1.
- Mühl, Thomas (2020). *Elektrische Messtechnik*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-29115-0. DOI: 10.1007/978-3-658-29116-7.
- Mühlnickel, Helmut; Cäcilia Maria Kurz; Philipp Jussen; Roman Emonts-Holley (2018). „Smart Maintenance“. In: *Betriebliche Instandhaltung*. Hrsg. von Jens Reichel; Gerhard Müller; Jean Haeffs. VDI-Buch. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 349–360. ISBN: 978-3-662-53134-1. DOI: 10.1007/978-3-662-53135-8_24.
- Mukherjee, Rajendrani; Pragma Kar (2017). „A Comparative Review of Data Warehousing ETL Tools with New Trends and Industry Insight“. In: *2017 IEEE 7th International Advance Computing Conference (IACC)*. IEEE, S. 943–948. ISBN: 978-1-5090-1560-3. DOI: 10.1109/IACC.2017.0192.
- Müller, Rainer; Matthias Vette-Steinkamp; Matthias Scholer; Leonie Schirmer; Anne Blum (2019). „Upgrading and Ensuring a Fully-Automated Assembly Process Using Tolerance Management Methods“. In: *Procedia CIRP* 81, S. 174–179. DOI: 10.1016/j.procir.2019.03.031.
- Mumuni, Alhassan; Fuseini Mumuni (2025). „Automated data processing and feature engineering for deep learning and big data applications: A survey“. In: *Journal of Information and Intelligence* 3.2, S. 113–153. DOI: 10.1016/j.jiixd.2024.01.002.
- Muniraj, Santhana Pandiyan; Xun Xu (2021). „An Implementation of OPC UA for Machine-to-Machine Communications in a Smart Factory“. In: *Procedia Manufacturing* 53, S. 52–58. DOI: 10.1016/j.promfg.2021.06.009.
- Munirathinam, Sathyan; B. Ramadoss (2014). „Big data predictive analytics for proactive semiconductor equipment maintenance“. In: *2014 IEEE International Conference on Big Data (Big Data)*. IEEE, S. 893–902. ISBN: 978-1-4799-5666-1. DOI: 10.1109/BigData.2014.7004320.
- Muraina, Ismail (2022). „IDEAL DATASET SPLITTING RATIOS IN MACHINE LEARNING ALGORITHMS: GENERAL CONCERNS FOR DATA SCIENTISTS AND DATA ANALYSTS“. In:
- Murphy, Kevin (2014). *Machine Learning - A Probabilistic Perspective*. Adaptive Computation and Machine Learning. Cambridge: MIT Press. ISBN: 0262018020.
- Murphy, Kevin P et al. (2006). „Naive bayes classifiers“. In: *University of British Columbia* 18.60, S. 1–8.
- Murtagh, Fionn (1991). „Multilayer perceptrons for classification and regression“. In: *Neurocomputing* 2.5-6, S. 183–197. DOI: 10.1016/0925-2312(91)90023-5.
- Muschelli, John (2020). „ROC and AUC with a Binary Predictor: a Potentially Misleading Metric“. In: *Journal of classification* 37.3, S. 696–708. DOI: 10.1007/s00357-019-09345-1.
- Mykhailyshyn, Roman; Volodymyr Savkiv; Pavlo Maruschak; Jing Xiao (2022). „A SYSTEMATIC REVIEW ON PNEUMATIC GRIPPING DEVICES FOR INDUSTRIAL ROBOTS“. In: *Transport* 37.3, S. 201–231. DOI: 10.3846/transport.2022.17110.

- Nadj, Mario; Alexander Maedche; Christian Schieder (2020). „The effect of interactive analytical dashboard features on situation awareness and task performance“. In: *Decision Support Systems* 135, S. 113322. DOI: 10.1016/j.dss.2020.113322.
- Nambiar, Athira; Divyansh Mundra (2022). „An Overview of Data Warehouse and Data Lake in Modern Enterprise Data Management“. In: *Big Data and Cognitive Computing* 6.4, S. 132. DOI: 10.3390/bdcc6040132.
- Nargesian, Fatemeh; Erkang Zhu; Renée J. Miller; Ken Q. Pu; Patricia C. Arocena (2019). „Data lake management“. In: *Proceedings of the VLDB Endowment* 12.12, S. 1986–1989. DOI: 10.14778/3352063.3352116.
- Natekin, Alexey; Alois Knoll (2013). „Gradient boosting machines, a tutorial“. In: *Frontiers in neurorobotics* 7, S. 21. DOI: 10.3389/fnbot.2013.00021.
- Navia-Vázquez, A.; E. Parrado-Hernández (2006). „Support vector machine interpretation“. In: *Neurocomputing* 69.13-15, S. 1754–1759. DOI: 10.1016/j.neucom.2005.12.118.
- Nemeth, Tanja; Fazel Ansari; Wilfried Sihn (2019). „A Maturity Assessment Procedure Model for Realizing Knowledge-Based Maintenance Strategies in Smart Manufacturing Enterprises“. In: *Procedia Manufacturing* 39, S. 645–654. DOI: 10.1016/j.promfg.2020.01.439.
- Nemeth, Tanja; Fazel Ansari; Wilfried Sihn; Bernhard Haslhofer; Alexander Schindler (2018). „PriMa-X: A reference model for realizing prescriptive maintenance and assessing its maturity enhanced by machine learning“. In: *Procedia CIRP* 72, S. 1039–1044. DOI: 10.1016/j.procir.2018.03.280.
- Netrapalli, Praneeth (2019). „Stochastic Gradient Descent and Its Variants in Machine Learning“. In: *Journal of the Indian Institute of Science* 99.2, S. 201–213. DOI: 10.1007/s41745-019-0098-4.
- Nguyen, Nam; Yunsong Guo (2008). „Metric Learning: A Support Vector Approach“. In: *Machine Learning and Knowledge Discovery in Databases*. Hrsg. von Walter Daelemans; Bart Goethals; Katharina Morik. Bd. 5212. Lecture Notes in Computer Science. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 125–136. ISBN: 978-3-540-87480-5. DOI: 10.1007/978-3-540-87481-2_9.
- Nick, Todd G.; Kathleen M. Campbell (2007). „Logistic regression“. In: *Methods in molecular biology (Clifton, N.J.)* 404, S. 273–301. DOI: 10.1007/978-1-59745-530-5_14.
- Nitsche, Anna-Maria; Christian-Andreas Schumann; Christoph Laroque; Olga Matthias (2021). „Multiple Perspektiven bei der Implementierung innovativer technologischer Lösungen im Kontext datengesteuerter Entscheidungsfindung“. In: *Data Science anwenden*. Hrsg. von Thomas Barton; Christian Müller. Angewandte Wirtschaftsinformatik. Wiesbaden: Springer Fachmedien Wiesbaden, S. 53–68. ISBN: 978-3-658-33812-1. DOI: 10.1007/978-3-658-33813-8_4.
- Noble, William S. (2006). „What is a support vector machine?“ In: *Nature biotechnology* 24.12, S. 1565–1567. DOI: 10.1038/nbt1206-1565.
- Nunes, D. M.; RDSG Campilho; F. J.G. Silva (2022). „Design of a transfer system for the automotive industry“. In: *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering* 236.5, S. 2044–2055. DOI: 10.1177/09544089221080042.

- Nuthalapati, Aravind (2024). „Architecting data lake-houses in the cloud: Best practices and future directions“. In: *International Journal of Science and Research Archive* 12.2, S. 1902–1909. DOI: 10.30574/ijrsra.2024.12.2.1466.
- O'Donovan, P.; K. Leahy; K. Bruton; D. T. J. O'Sullivan (2015). „An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities“. In: *Journal of Big Data* 2.1. DOI: 10.1186/s40537-015-0034-z.
- O'Shea, Keiron; Ryan Nash (2015). „An Introduction to Convolutional Neural Networks“. In: DOI: 10.48550/arXiv.1511.08458.
- Oehlerking, Friederike (2024). *Mit Daten überzeugen, mit Geschichten inspirieren*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-68493-1. DOI: 10.1007/978-3-662-68494-8.
- Ofoeda, Joshua; Richard Boateng; John Effah (2019). „Application Programming Interface (API) Research“. In: *International Journal of Enterprise Information Systems* 15.3, S. 76–95. DOI: 10.4018/IJEIS.2019070105.
- Al-Okaily, Aws; Manaf Al-Okaily; Ai Ping Teoh; Mutaz M. Al-Debei (2023). „An empirical study on data warehouse systems effectiveness: the case of Jordanian banks in the business intelligence era“. In: *EuroMed Journal of Business* 18.4, S. 489–510. DOI: 10.1108/EMJB-01-2022-0011.
- Oleghe, Omogbai; Konstantinos Salonitis (2020). „A framework for designing data pipelines for manufacturing systems“. In: *Procedia CIRP* 93, S. 724–729. DOI: 10.1016/j.procir.2020.04.016.
- Ordieres-Meré, Joaquín; Antonio Sánchez-Herguedas; Ángel Mena-Nieto (2025). „A Data-Driven Monitoring System for a Prescriptive Maintenance Approach: Supporting Reinforcement Learning Strategies“. In: *Applied Sciences* 15.12, S. 6917. DOI: 10.3390/app15126917.
- Ormerod, R. (2006). „The history and ideas of pragmatism“. In: *Journal of the Operational Research Society* 57.8, S. 892–909. DOI: 10.1057/palgrave.jors.2602065.
- Orošnjak, Marko; Felix Saretzky; Slawomir Kedziora (2025). „Prescriptive Maintenance: A Systematic Literature Review and Exploratory Meta-Synthesis“. In: *Applied Sciences* 15.15, S. 8507. DOI: 10.3390/app15158507.
- Ouadah, Abdelfettah; Leila Zemmouchi-Ghomari; Nedjma Salhi (2022). „Selecting an appropriate supervised machine learning algorithm for predictive maintenance“. In: *The International Journal of Advanced Manufacturing Technology* 119.7-8, S. 4277–4301. DOI: 10.1007/s00170-021-08551-9.
- Páez, Antonio; Geneviève Boisjoly (2022). „Exploratory Data Analysis“. In: *Discrete Choice Analysis with R*. Hrsg. von Antonio Páez; Geneviève Boisjoly. Use R! Cham: Springer International Publishing, S. 25–64. ISBN: 978-3-031-20718-1. DOI: 10.1007/978-3-031-20719-8_2.
- Pagan, Muasir; Muhammad Zarlis; Ade Candra (2023). „Investigating the impact of data scaling on the k-nearest neighbor algorithm“. In: *Computer Science and Information Technologies* 4.2, S. 135–142. DOI: 10.11591/cs.it.v4i2.pp135-142.
- Pagan, Nicolò; Joachim Baumann; Ezzat Elokda; Giulia de Pasquale; Saverio Bolognani; Anikó Hannák (2023). „A Classification of Feedback Loops and Their Relation to

- Biases in Automated Decision-Making Systems“. In: *Equity and Access in Algorithms, Mechanisms, and Optimization*. New York: ACM, S. 1–14. ISBN: 9798400703812. DOI: 10.1145/3617694.3623227.
- Paleyev, Andrei; Raoul-Gabriel Urma; Neil D. Lawrence (2023). „Challenges in Deploying Machine Learning: A Survey of Case Studies“. In: *ACM Computing Surveys* 55.6, S. 1–29. DOI: 10.1145/3533378.
- Pan, Bin; Guomin Zhang; Xuepei Qin (2018). „Design and realization of an ETL method in business intelligence project“. In: *2018 IEEE 3rd International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*. IEEE, S. 275–279. ISBN: 978-1-5386-4301-3. DOI: 10.1109/ICCCBDA.2018.8386526.
- Paolanti, Marina; Luca Romeo; Andrea Felicetti; Adriano Mancini; Emanuele Frontoni; Jelena Loncarski (2018). „Machine Learning approach for Predictive Maintenance in Industry 4.0“. In: S. 1–6. DOI: 10.1109/MESA.2018.8449150.
- Papp, Stefan; Wolfgang Weidinger; Katherine Munro; Bernhard Ortner; Annalisa Cadonna; Georg Langs; Roxane Licandro; Mario Meir-Huber; Danko Nikolić; Zoltan Toth; Barbora Vesela; Rania Wazir; Günther Zauner (2022). *Handbuch Data Science und KI: Mit Machine Learning und Datenanalyse Wert aus Daten generieren*. 2. Aufl. München: Hanser. ISBN: 978-3-446-47245-7.
- Parapalli, Shriprakashan L.; Jithen Shetty (2025). „Leveraging Hybrid Edge-Cloud Predictive Maintenance in Pharmaceutical MES: An Industry 4.0 Approach Using Big Data“. In: *Journal of Computer Science and Technology Studies* 7.2, S. 86–94. DOI: 10.32996/jcsts.2025.7.2.7.
- Parmar, Aakash; Rakesh Katariya; Vatsal Patel (2019). „A Review on Random Forest: An Ensemble Classifier“. In: *International Conference on Intelligent Data Communication Technologies and Internet of Things (ICICI) 2018*. Hrsg. von Jude Hemanth; Xavier Fernando; Pavel Lafata; Zubair Baig. Bd. 26. Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer International Publishing, S. 758–763. ISBN: 978-3-030-03145-9. DOI: 10.1007/978-3-030-03146-6_86.
- Parthier, Rainer (2020). *Messtechnik*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-27130-5. DOI: 10.1007/978-3-658-27131-2.
- Passi, Samir; Solon Barocas (2019). „Problem Formulation and Fairness“. In: *Proceedings of the Conference on Fairness, Accountability, and Transparency*. New York: ACM, S. 39–48. ISBN: 9781450361255. DOI: 10.1145/3287560.3287567.
- Patil, Dipti D; VM Wadhai; JA Gokhale (o.D.). „Evaluation of decision tree pruning algorithms for complexity and classification accuracy“. In: *International Journal of Computer Applications* 11.2 (), S. 23–30.
- Pavlu, Jindrich; Vaclav Legat; Zdenek Ales (2019). „Estimation trends in the maintenance of a manufacturing equipment relation to the industry 4.0 challenge“. In: *Proceedings of the 7th International Conference on Trends in Agricultural Engineering*.
- Pavoni, Gaia; Massimiliano Corsini; Federico Ponchio; Alessandro Muntoni; Clinton Edwards; Nicole Pedersen; Stuart Sandin; Paolo Cignoni (2022). „TagLab: AI-assisted annotation for the fast and accurate semantic segmentation of coral reef orthoimages“. In: *Journal of Field Robotics* 39.3, S. 246–262. DOI: 10.1002/rob.22049.

- Pawar, N. B.; P. P. Patil; R. Y. Patil (2017). „A Review : Design And Analysis of Welding Fixture for the Rack and Pinion Assembly“. In: *International Journal of Scientific Research in Science, Engineering and Technology (IJSRSET)* 3, S. 30–33.
- Pawellek, Günther (2013). *Integrierte Instandhaltung und Ersatzteillogistik: Vorgehensweisen, Methoden, Tools*. Berlin: Springer Vieweg. ISBN: 978-3-642-31383-7.
- Pearl, Judea; Dana Mackenzie (2018). *The book of why: The new science of cause and effect*. 1. Aufl. New York: Basic Books. ISBN: 9780465097609.
- Pech, Martin; Jaroslav Vrchota; Jiří Bednář (2021). „Predictive Maintenance and Intelligent Sensors in Smart Factory: Review“. In: *Sensors (Basel, Switzerland)* 21.4. DOI: 10.3390/s21041470.
- Peffer, Ken; Tuure Tuunanen; Marcus A. Rothenberger; Samir Chatterjee (2007). „A Design Science Research Methodology for Information Systems Research“. In: *Journal of Management Information Systems* 24.3, S. 45–77. DOI: 10.2753/MIS0742-1222240302.
- Peng, Jinglin; Weiyuan Wu; Brandon Lockhart; Song Bian; Jing Nathan Yan; Linghao Xu; Zhixuan Chi; Jeffrey M. Rzeszutarski; Jiannan Wang (2021). „DataPrep.EDA: Task-Centric Exploratory Data Analysis for Statistical Modeling in Python“. In: *Proceedings of the 2021 International Conference on Management of Data*. Hrsg. von Guoliang Li; Zhanhuai Li; Stratos Idreos; Divesh Srivastava. New York: ACM, S. 2271–2280. ISBN: 9781450383431. DOI: 10.1145/3448016.3457330.
- Petrović, Marko; Milica Vučković; Nina Turajlić; Slađan Babarogić; Nenad Aničić; Zoran Marjanović (2017). „Automating ETL processes using the domain-specific modeling approach“. In: *Information Systems and e-Business Management* 15.2, S. 425–460. DOI: 10.1007/s10257-016-0325-8.
- Pham, Hung; Quang-Cuong Pham (2019). „Critically fast pick-and-place with suction cups“. In: *2019 International Conference on Robotics and Automation (ICRA)*. IEEE, S. 3045–3051. ISBN: 978-1-5386-6027-0. DOI: 10.1109/ICRA.2019.8794081.
- Philip Chen, C. L.; Chun-Yang Zhang (2014). „Data-intensive applications, challenges, techniques and technologies: A survey on Big Data“. In: *Information Sciences* 275, S. 314–347. DOI: 10.1016/j.ins.2014.01.015.
- Plevris, V.; G. Solorzano; N. Bakas; M. Ben Seghier (2022). „Investigation of performance metrics in regression analysis and machine learning-based prediction models“. In: *8th European Congress on Computational Methods in Applied Sciences and Engineering*. CIMNE. DOI: 10.23967/eccomas.2022.155.
- Ponnuswami, Ganesan; Sriram Kailasam; Dileep Aroor Dinesh (2020). „Event-Driven Data Pipeline for Network Management Systems“. In: *2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. IEEE, S. 1–6. ISBN: 978-1-7281-6851-7. DOI: 10.1109/ICCCNT49239.2020.9225344.
- Poor, P.; J. Basl; D. Zenisek (2019). „Predictive Maintenance 4.0 as next evolution step in industrial maintenance development“. In: *2019 International Research Conference on Smart Computing and Systems Engineering (SCSE)*. IEEE, S. 245–253. ISBN: 978-955-704-121-6. DOI: 10.23919/SCSE.2019.8842659.

- Potes Ruiz, Paula; Bernard Kamsu Foguem; Bernard Grabot (2014). „Generating knowledge in maintenance from Experience Feedback“. In: *Knowledge-Based Systems* 68, S. 4–20. DOI: 10.1016/j.knosys.2014.02.002.
- Prasad Nepal, Madhav; Moonseo Park (2004). „Downtime model development for construction equipment management“. In: *Engineering, Construction and Architectural Management* 11.3, S. 199–210. DOI: 10.1108/09699980410535804.
- Prechelt, Lutz (1998). „Automatic early stopping using cross validation: quantifying the criteria“. In: *Neural networks : the official journal of the International Neural Network Society* 11.4, S. 761–767. DOI: 10.1016/S0893-6080(98)00010-0.
- Pretty, D. G.; B. D. Blackwell (2009). „A data mining algorithm for automated characterisation of fluctuations in multichannel timeseries“. In: *Computer Physics Communications* 180.10, S. 1768–1776. DOI: 10.1016/j.cpc.2009.05.003.
- Puente León, Fernando (2019). *Messtechnik*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-59766-8. DOI: 10.1007/978-3-662-59767-5.
- Pyle, Dorian (2005). *Data preparation for data mining*. San Francisco: Morgan Kaufmann. ISBN: 1558605290.
- Qi, Qinglin; Fei Tao (2018). „Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison“. In: *IEEE Access* 6, S. 3585–3593. DOI: 10.1109/ACCESS.2018.2793265.
- Quix, Christoph (2021). „Data Engineering“. In: *Data Science*. Hrsg. von Detlev Frick; Andreas Gadatsch; Jens Kaufmann; Birgit Lankes; Christoph Quix; Andreas Schmidt; Uwe Schmitz. Wiesbaden: Springer Fachmedien Wiesbaden, S. 85–104. ISBN: 978-3-658-33402-4. DOI: 10.1007/978-3-658-33403-1_5.
- Rahm, Erhard; Hong Hai Do (2000). „Data Cleaning: Problems and Current Approaches.“ In: *IEEE Data(base) Engineering Bulletin* 23, S. 3–13. URL: <https://api.semanticscholar.org/CorpusID:260972099>.
- Rahman, Azizah Abdul; Yunusa Bena Adamu; Pershella Harun (2017). „Review on dashboard application from managerial perspective“. In: *2017 International Conference on Research and Innovation in Information Systems (ICRIIS)*. IEEE, S. 1–5. ISBN: 978-1-5090-3035-4. DOI: 10.1109/ICRIIS.2017.8002461.
- Rahmani, Keyvan; Rahul Thapa; Peiling Tsou; Satish Casie Chetty; Gina Barnes; Carson Lam; Chak Foon Tso (2023). „Assessing the effects of data drift on the performance of machine learning models used in clinical sepsis prediction“. In: *International journal of medical informatics* 173, S. 104930. DOI: 10.1016/j.ijmedinf.2022.104930.
- Raj, Aiswarya; Jan Bosch; Helena Holmstrom Olsson; Tian J. Wang (2020). „Modelling Data Pipelines“. In: *2020 46th Euromicro Conference on Software Engineering and Advanced Applications (SEAA)*. IEEE, S. 13–20. ISBN: 978-1-7281-9532-2. DOI: 10.1109/SEAA51224.2020.00014.
- Rajpathak, Dnyanesh; Rahul Chougule; Pulak Bandyopadhyay (2012). „A domain-specific decision support system for knowledge discovery using association and text mining“. In: *Knowledge and Information Systems* 31.3, S. 405–432. DOI: 10.1007/s10115-011-0409-1.

- Ramasamy, Anandhi; Soumitra Chowdhury (2020). „Big Data Quality Dimensions: A Systematic Literature Review“. In: *Journal of Information Systems and Technology Management*. DOI: 10.4301/S1807-1775202017003.
- Rasch, Björn; Wilhelm Hofmann; Malte Frieze; Ewald Naumann (2010). „Deskriptive Statistik“. In: *Quantitative Methoden*. Hrsg. von Björn Rasch; Wilhelm Hofmann; Malte Frieze; Ewald Naumann. Springer-Lehrbuch. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 1–28. ISBN: 978-3-642-05271-2. DOI: 10.1007/978-3-642-05272-9_1.
- Rashid, A. N. M. Bazlur; Mohiuddin Ahmed; Abu Barkat Ullah (2022). „Data Lakes: A Panacea for Big Data Problems, Cyber Safety Issues, and Enterprise Security“. In: *Next-Generation Enterprise Security and Governance*. Hrsg. von Mohiuddin Ahmed; Nour Moustafa; Abu Barkat; Paul Haskell-Dowland. Boca Raton: CRC Press, S. 135–162. ISBN: 9781003121541. DOI: 10.1201/9781003121541-6.
- Ratner, Alexander; Stephen H. Bach; Henry Ehrenberg; Jason Fries; Sen Wu; Christopher Ré (2020). „Snorkel: rapid training data creation with weak supervision“. In: *The VLDB journal : very large data bases : a publication of the VLDB Endowment* 29.2, S. 709–730. DOI: 10.1007/s00778-019-00552-1.
- Rauber, Natalie; Stefan Georg (2021). „Überblick über das Prozesskostenmanagement“. In: *Prozesskostenmanagement in der Industrie*. Hrsg. von Natalie Rauber; Stefan Georg. essentials. Wiesbaden: Springer Fachmedien Wiesbaden, S. 15–20. ISBN: 978-3-658-35297-4. DOI: 10.1007/978-3-658-35298-1_3.
- Rausch, Thomas; Stefan Nastic; Schahram Dustdar (2018). „EMMA: Distributed QoS-Aware MQTT Middleware for Edge Computing Applications“. In: *2018 IEEE International Conference on Cloud Engineering (IC2E)*. IEEE, S. 191–197. ISBN: 978-1-5386-5008-0. DOI: 10.1109/IC2E.2018.00043.
- Ravat, Franck; Yan Zhao (2019). „Data Lakes: Trends and Perspectives“. In: *Database and Expert Systems Applications*. Hrsg. von Sven Hartmann; Josef Küng; Sharma Chakravarthy; Gabriele Anderst-Kotsis; A. Min Tjoa; Ismail Khalil. Bd. 11706. Lecture Notes in Computer Science. Cham: Springer International Publishing, S. 304–313. ISBN: 978-3-030-27614-0. DOI: 10.1007/978-3-030-27615-7_23.
- Ravi, Vamsee Krishna; Aravind Ayyagari; Kodamasimhan Krishna; Punit Goel; Akshun Chhapola; Arpit Jain (2023). „Data Lake Implementation in Enterprise Environments“. In: *International Journal of Progressive Research in Engineering Management and Science (IJPREAMS) Vol 3*.
- Razavi, Kamran; Mehran Salmani; Max Mühlhäuser; Boris Koldehofe; Lin Wang (2024). „A Tale of Two Scales: Reconciling Horizontal and Vertical Scaling for Inference Serving Systems“. In: DOI: 10.48550/arXiv.2407.14843.
- Razzouki, Otmane Filali; Anas Charroud; Zakaria El Allali; Abdelaziz Chetouani; Nassime Aslimani (2024). „A Survey of Advanced Gradient Methods in Machine Learning“. In: *2024 7th International Conference on Advanced Communication Technologies and Networking (CommNet)*. IEEE, S. 1–7. ISBN: 979-8-3503-6702-7. DOI: 10.1109/CommNet63022.2024.10793249.
- Reddy, S. Sai Satyanarayana; A. Lavanya; V. Khanna; L.S.S. Reddy (2009). „Research Issues on Data Warehouse Maintenance“. In: *2009 International Conference on Advanced*

- Computer Control*. IEEE, S. 623–627. ISBN: 978-0-7695-3516-6. DOI: 10.1109/ICACC.2009.144.
- Reid Turner, C.; Alfonso Fuggetta; Luigi Lavazza; Alexander L. Wolf (1999). „A conceptual basis for feature engineering“. In: *Journal of Systems and Software* 49.1, S. 3–15. DOI: 10.1016/S0164-1212(99)00062-X.
- Ren, Shan; Yingfeng Zhang; Tomohiko Sakao; Yang Liu; Ruilong Cai (2022). „An Advanced Operation Mode with Product-Service System Using Lifecycle Big Data and Deep Learning“. In: *International Journal of Precision Engineering and Manufacturing-Green Technology* 9.1, S. 287–303. DOI: 10.1007/s40684-021-00354-3.
- Reuter, Wolfgang; Anna Korotkova; Linh Nguyen (2023). „Strukturierte und unstrukturierte Daten“. In: *Künstliche Intelligenz und Data Science in Theorie und Praxis*. Hrsg. von Andreas Gillhuber; Göran Kauermann; Wolfgang Hauner. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 51–68. ISBN: 978-3-662-66277-9. DOI: 10.1007/978-3-662-66278-6_5.
- Rey, Günter Daniel; Karl F. Wender (2018). *Neuronale Netze*. Hogrefe. ISBN: 9783456857961. DOI: 10.1024/85796-000.
- Riccio, Vincenzo; Gunel Jahangirova; Andrea Stocco; Nargiz Humbatova; Michael Weiss; Paolo Tonella (2020). „Testing machine learning based systems: a systematic mapping“. In: *Empirical Software Engineering* 25.6, S. 5193–5254. DOI: 10.1007/s10664-020-09881-0.
- Rich, Elaine (1985). „Artificial Intelligence and the Humanities“. In: *Computers and the Humanities* 19.2, S. 117–122.
- Rish, Irina (2001). „An Empirical Study of the Naïve Bayes Classifier“. In: 3. URL: https://www.researchgate.net/profile/irina-rish/publication/228845263_an_empirical_study_of_the_naive_bayes_classifier.
- Rittel, Horst W. J.; Melvin M. Webber (1973). „Dilemmas in a general theory of planning“. In: *Policy Sciences* 4.2, S. 155–169. DOI: 10.1007/BF01405730.
- Roelofs, Erik; Lucas Persoon; Sebastiaan Nijsten; Wolfgang Wiessler; André Dekker; Philippe Lambin (2013). „Benefits of a clinical data warehouse with data mining tools to collect data for a radiotherapy trial“. In: *Radiotherapy and oncology : journal of the European Society for Therapeutic Radiology and Oncology* 108.1, S. 174–179. DOI: 10.1016/j.radonc.2012.09.019.
- Roelofs, Rebecca; Vaishaal Shankar; Benjamin Recht; Sara Fridovich-Keil; Moritz Hardt; John Miller; Ludwig Schmidt (2019). „A Meta-Analysis of Overfitting in Machine Learning“. In: *Advances in Neural Information Processing Systems*. Hrsg. von H. Wallach; H. Larochelle; A. Beygelzimer; F. d’Alché-Buc; E. Fox; R. Garnett. Bd. 32. Curran Associates, Inc.
- Rohweder, Jan P.; Gerhard Kasten; Dirk Malzahn; Andrea Piro; Joachim Schmid (2008). „Informationsqualität — Definitionen, Dimensionen und Begriffe“. In: *Daten- und Informationsqualität*. Hrsg. von Knut Hildebrand; Marcus Gebauer; Holger Hinrichs; Michael Mielke. Wiesbaden: Vieweg+Teubner, S. 25–45. ISBN: 978-3-8348-0321-4. DOI: 10.1007/978-3-8348-9266-9_2.

- Rosenthal, Arnon S.; Edward Sciore (2000). „View security as the basis for data warehouse security“. In: *Design and Management of Data Warehouses*. URL: <https://api.semanticscholar.org/CorpusID:4723814>.
- Rötzel, Adolf; Iris Rötzel-Schwunk (2017). *Instandhaltung: Eine betriebliche Herausforderung*. 5. Aufl. Berlin und Offenbach: VDE Verlag. ISBN: 978-3-8007-4003-1.
- Rowley, Jennifer (1999). „What is knowledge management?“ In: *Library Management* 20.8, S. 416–420. DOI: 10.1108/01435129910291175.
- Rowley, Jennifer; Frances Slack (2004). „Conducting a literature review“. In: *Management Research News* 27.6, S. 31–39. DOI: 10.1108/01409170410784185.
- Runkler, Thomas A. (2015). „Datenvorverarbeitung“. In: *Data Mining*. Hrsg. von Thomas A. Runkler. Wiesbaden: Springer Fachmedien Wiesbaden, S. 23–36. ISBN: 978-3-8348-1694-8. DOI: 10.1007/978-3-8348-2171-3_3.
- (2020). „Data Preprocessing“. In: *Data Analytics*. Hrsg. von Thomas A. Runkler. Wiesbaden: Springer Fachmedien Wiesbaden, S. 23–36. ISBN: 978-3-658-29778-7. DOI: 10.1007/978-3-658-29779-4_3.
- Ryll, Frank (2008). *Gestaltung einer zustandsorientierten Instandhaltungsstrategie auf der Grundlage einer erfahrungsbasierten Bewertung von Abnutzungsvorräten in technischen Anlagen: Zugl.: Magdeburg, Univ., Fak. für Maschinenbau, Diss., 2008*. Stuttgart: Fraunhofer IRB Verl. ISBN: 9783816776581.
- Ryll, Frank; Curt Freund (2010). „Grundlagen der Instandhaltung“. In: *Instandhaltung technischer Systeme*. Hrsg. von Michael Schenk. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 23–101. ISBN: 978-3-642-03948-5. DOI: 10.1007/978-3-642-03949-2_2.
- Sagala, Noviyanti T. M.; Fonggi Yudi Aryatama (2022). „Exploratory Data Analysis (EDA): A Study of Olympic Medallist“. In: *SISTEMASI* 11.3, S. 578. DOI: 10.32520/stmsi.v11i3.1857.
- Salehinejad, Hojjat; Sharan Sankar; Joseph Barfett; Errol Colak; Shahrokh Valaee (2018). „Recent Advances in Recurrent Neural Networks“. In: DOI: 10.48550/arXiv.1801.01078.
- Salipante, Paul; William Notz; John Bigelow (1982). „A matrix approach to literature reviews“. In: *Research in organizational behavior* 4, S. 321–348.
- Salman, Hasan Ahmed; Ali Kalakech; Amani Steiti (2024). „Random Forest Algorithm Overview“. In: *Babylonian Journal of Machine Learning* 2024, S. 69–79. DOI: 10.58496/BJML/2024/007.
- Salmi, Nafizatus; Zuherman Rustam (2019). „Naïve Bayes Classifier Models for Predicting the Colon Cancer“. In: *IOP Conference Series: Materials Science and Engineering* 546.5, S. 052068. DOI: 10.1088/1757-899X/546/5/052068.
- Samuels, Warren J. (2000). „Signs, Pragmatism, and Abduction: The Tragedy, Irony, and Promise of Charles Sanders Peirce“. In: *Journal of Economic Issues* 34.1, S. 207–217. DOI: 10.1080/00213624.2000.11506254.
- Sang, Go Muan; Lai Xu; Paul de Vrieze (2021). „A Predictive Maintenance Model for Flexible Manufacturing in the Context of Industry 4.0“. In: *Frontiers in big data* 4, S. 663466. DOI: 10.3389/fdata.2021.663466.

- Sang, Go Muan; Lai Xu; Paul de Vrieze; Yuewei Bai; Fangyu Pan (2020). „Predictive Maintenance in Industry 4.0“. In: *Proceedings of the 10th International Conference on Information Systems and Technologies*. Hrsg. von Mohamed Ridda Laouar; Antonio Capodieci. New York: ACM, S. 1–11. ISBN: 9781450376556. DOI: 10.1145/3447568.3448537.
- Santos, Cleiton Ferreira dos; Rolando Jacyr Kurscheidt Netto; Ricardo Eiji Kondo; Eduardo de Freitas Rocha Loures; Eduardo Alves Portela Santos; Anderson Luis Szejka (2023). „A Hybrid Architecture of Digital Twin with Decision Support Layer for Industrial Maintenance“. In: *Flexible Automation and Intelligent Manufacturing: The Human-Data-Technology Nexus*. Hrsg. von Kyoung-Yun Kim; Leslie Monplaisir; Jeremy Rickli. Lecture Notes in Mechanical Engineering. Cham: Springer International Publishing, S. 584–591. ISBN: 978-3-031-17628-9. DOI: 10.1007/978-3-031-17629-6_61.
- El-Sappagh, Shaker H. Ali; Abdeltawab M. Ahmed Hendawi; Ali Hamed El Bastawissy (2011). „A proposed model for data warehouse ETL processes“. In: *Journal of King Saud University - Computer and Information Sciences* 23.2, S. 91–104. DOI: 10.1016/j.jksuci.2011.05.005.
- Sarikaya, Alper; Michael Correll; Lyn Bartram; Melanie Tory; Danyel Fisher (2018). „What Do We Talk About When We Talk About Dashboards?“ In: *IEEE transactions on visualization and computer graphics*. DOI: 10.1109/TVCG.2018.2864903.
- Sawicki, Tadeusz (2021). „Improved rack and pinion drive“. In: *Technical Transactions*, S. 1–7. DOI: 10.37705/techtrans/e2021013.
- Schaffner, Michael (2019). „Industrie 4.0: Technische Redakteure werden zu Semantikmodellierern“. In: *Arbeitswelten der Zukunft*. Hrsg. von Burghard Hermeier; Thomas Heupel; Sabine Fichtner-Rosada. FOM-Edition. Wiesbaden: Springer Fachmedien Wiesbaden, S. 107–129. ISBN: 978-3-658-23396-9. DOI: 10.1007/978-3-658-23397-6_7.
- Schendera, Christian FG (2015). *Deskriptive Statistik verstehen*. Bd. 3969. UTB.
- Schenkelberg, Kai; Ulrich Seidenberg; Fazel Ansari (2020). „Analyzing the impact of maintenance on profitability using dynamic bayesian networks“. In: *Procedia CIRP* 88, S. 42–47. DOI: 10.1016/j.procir.2020.05.008.
- Schiuma, Giovanni; Daniela Carlucci; Francesco Sole (2012). „Applying a systems thinking framework to assess knowledge assets dynamics for business performance improvement“. In: *Expert Systems with Applications* 39.9, S. 8044–8050. DOI: 10.1016/j.eswa.2012.01.139.
- Schlotmann, Raimund (2018). *Digitalisierung auf mittelständisch*. Berlin und Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-55736-5. DOI: 10.1007/978-3-662-55737-2.
- Schmidt, Bernard; Lihui Wang (2018). „Cloud-enhanced predictive maintenance“. In: *The International Journal of Advanced Manufacturing Technology* 99.1-4, S. 5–13. DOI: 10.1007/s00170-016-8983-8.
- Schmidt, Johannes; Antonius van Hoof; Stefan Kühne (2013). „Konzeption einer digitalen Lebenslaufakte für Erneuerbare-Energie-Anlagen“. In: *Energieinformatik 2013*. Hrsg.

- von Peter Palensky. Österreichische Computer Gesellschaft, S. 141–146. ISBN: 978-3-85403-298-4.
- Schmidt, Robin M. (2019). „Recurrent Neural Networks (RNNs): A gentle Introduction and Overview“. In: DOI: 10.48550/arXiv.1912.05911.
- Schmitt, Robert; Tilo Pfeifer (2010). *Qualitätsmanagement: Strategien, Methoden, Techniken*. 4. Aufl. Carl Hanser Fachbuchverlag. ISBN: 978-3-446-42647-4. DOI: 10.3139/9783446426474.
- Schneider, Jan; Christoph Gröger; Arnold Lutsch; Holger Schwarz; Bernhard Mitschang (2024). „The Lakehouse: State of the Art on Concepts and Technologies“. In: *SN Computer Science* 5.5. DOI: 10.1007/s42979-024-02737-0.
- Schneider, Matthias; Dominik Lucke; Thomas Adolf (2019). „A Cyber-Physical Failure Management System for Smart Factories“. In: *Procedia CIRP* 81, S. 300–305. DOI: 10.1016/j.procir.2019.03.052.
- Schneider, Tizian; Nikolai Helwig; Andreas Schutze (2018). „Automatic feature extraction and selection for condition monitoring and related datasets“. In: *2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. IEEE, S. 1–6. ISBN: 978-1-5386-2222-3. DOI: 10.1109/I2MTC.2018.8409763.
- Schröder, Tim; Michael Schulz (2022). „Monitoring machine learning models: a categorization of challenges and methods“. In: *Data Science and Management* 5.3, S. 105–116. DOI: 10.1016/j.dsm.2022.07.004.
- Schröder, Werner (2010). *Ganzheitliches Instandhaltungsmanagement: Aufbau, Ausgestaltung und Bewertung: Zugl.: Leoben, Montanuniv., Diss., 2009*. 1. Aufl. Gabler Research Techno-ökonomische Forschung und Praxis. Wiesbaden: Gabler. ISBN: 978-3-8349-2038-6.
- Schuh, Günther; Achim Kampker; Romeo Odak (2009). *Verfügbarkeitsorientierte Instandhaltung - Stellhebel zur Steigerung der Verfügbarkeit in produzierenden Unternehmen (VERSTAND): Verbundprojekt im Rahmenkonzept "Forschung für die Produktion von morgen" des Bundesministeriums für Bildung und Forschung (BMBF)*. Hrsg. von Günther Schuh. Bd. 4. Edition Wissenschaft. Aachen: Apprimus-Verl. ISBN: 978-3-940565-98-3.
- Schuh, Günther; Christoph Kelzenberg; Jens Helbig; Tim Graberg (2021). „Vorgehen zur Entwicklung einer Predictive Maintenance-Lösung“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 116.3, S. 149–152. DOI: 10.1515/zwf-2021-0029.
- Schuler GmbH (1998). *Metal forming handbook*. Berlin und New York: Springer-Verlag. ISBN: 9783540611851.
- Schulz, Esther; Alexander Pflaum (2021). „Erfolgsfaktoren bei der Entwicklung datengetriebener Geschäftsmodelle: Einblicke aus dem produzierenden Gewerbe“. In: *Services Management und digitale Transformation: Impulse und Beispiele für die erfolgreiche Umsetzung digitaler Services*, S. 47–67.
- Schulz, Thomas (2022). *Analytics in der Industrie: Schlüsseltechnologie für die digitale Transformation*. 1. Aufl. Würzburg: Vogel Buchverlag. ISBN: 9783834362933.

- Segel, Edward; Jeffrey Heer (2010). „Narrative visualization: telling stories with data“. In: *IEEE transactions on visualization and computer graphics* 16.6, S. 1139–1148. DOI: 10.1109/TVCG.2010.179.
- Settles, Burr (2009). „Active learning literature survey“. In:
- Shafiei, Somayeh B.; Saeed Shadpour; James L. Mohler; Kristopher Attwood; Qian Liu; Camille Gutierrez; Mehdi Seilanian Toussi (2023). „Developing surgical skill level classification model using visual metrics and a gradient boosting algorithm“. In: *Annals of surgery open : perspectives of surgical history, education, and clinical approaches* 4.2. DOI: 10.1097/AS9.0000000000000292.
- Shafique, Umair; Haseeb Qaiser (Nov. 2014). „A Comparative Study of Data Mining Process Models (KDD, CRISP-DM and SEMMA)“. In: *International Journal of Innovation and Scientific Research* 12, S. 2351–8014.
- Shaheen, Basheer Wasef; István Németh (2022). „Integration of Maintenance Management System Functions with Industry 4.0 Technologies and Features—A Review“. In: *Processes* 10.11, S. 2173. DOI: 10.3390/pr10112173.
- Shahzad, Khurram; Mattias Onils (2018). „Condition Monitoring in Industry 4.0-Design Challenges and Possibilities: A Case Study“. In: *2018 Workshop on Metrology for Industry 4.0 and IoT*. IEEE, S. 101–106. ISBN: 978-1-5386-2497-5. DOI: 10.1109/METRO14.2018.8428306.
- Shi, Chengming; George Panoutsos; Bo Luo; Hongqi Liu; Bin Li; Xu Lin (2019). „Using Multiple-Feature-Spaces-Based Deep Learning for Tool Condition Monitoring in Ultraprecision Manufacturing“. In: *IEEE Transactions on Industrial Electronics* 66.5, S. 3794–3803. DOI: 10.1109/TIE.2018.2856193.
- Shi, Yu; Joe Zhu; Vincent Charles (2021). „Data science and productivity: A bibliometric review of data science applications and approaches in productivity evaluations“. In: *Journal of the Operational Research Society* 72.5, S. 975–988. DOI: 10.1080/01605682.2020.1860661.
- Shin, Changho; Winfred Li; Harit Vishwakarma; Nicholas Roberts; Frederic Sala (2021). „Universalizing Weak Supervision“. In: DOI: 10.48550/arXiv.2112.03865.
- Shiyal, Bhadrash (2021). „Modern Data Warehouses and Data Lakehouses“. In: *Beginning Azure Synapse Analytics*. Hrsg. von Bhadrash Shiyal. Berkeley: Apress, S. 21–48. ISBN: 978-1-4842-7060-8. DOI: 10.1007/978-1-4842-7061-5_2.
- Sibindi, Racheal; Ronald Waweru Mwangi; Anthony Gichuhi Waititu (2023). „A boosting ensemble learning based hybrid light gradient boosting machine and extreme gradient boosting model for predicting house prices“. In: *Engineering Reports* 5.4. DOI: 10.1002/eng2.12599.
- Siemens AG (2025). *CMS X-Tools – Überblick*. Herstellerdokumentation zu Funktionen wie Analyse, Visualisierung, Archivierung und Systemeinbettung. URL: <https://support.industry.siemens.com/cs/document/109749256/cms-x-tools> (besucht am 18.10.2025).
- Siener, M; JC Aurich (2011). „Quality oriented maintenance scheduling“. In: *CIRP Journal of manufacturing science and technology* 4.1, S. 15–23.

- Silva, Beatriz; Francini Hak; Tiago Guimarães; Maria Manuel; Manuel Filipe Santos (2023). „Rule-based System for Effective Clinical Decision Support“. In: *Procedia Computer Science* 220, S. 880–885. DOI: 10.1016/j.procs.2023.03.119.
- Silveira Rocha, Murilo; Guilherme Serpa Sestito; Andre Luis Dias; Afonso Celso Turcato; Dennis Brandao (2018). „Performance Comparison Between OPC UA and MQTT for Data Exchange“. In: *2018 Workshop on Metrology for Industry 4.0 and IoT*. IEEE, S. 175–179. ISBN: 978-1-5386-2497-5. DOI: 10.1109/METRO14.2018.8428342.
- Simon, Herbert A. (1996). *The sciences of the artificial*. 3]. Cambridge: MIT Press. ISBN: 9780262193740.
- Singh, Aashi; Shilpi Sharma (2017). „Analysis on data mining models for internet of things“. In: *2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*. IEEE, S. 94–100.
- Singh, Ajit (2019). „Architecture of Data Lake“. In: *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, S. 411–414. DOI: 10.32628/CSEIT1952121.
- Singh, Meena; M. A. Rajan; V. L. Shivraj; P. Balamuralidhar (2015). „Secure MQTT for Internet of Things (IoT)“. In: *2015 Fifth International Conference on Communication Systems and Network Technologies*. IEEE, S. 746–751. ISBN: 978-1-4799-1797-6. DOI: 10.1109/CSNT.2015.16.
- Singh, Pradeep (2022). *Fundamentals and Methods of Machine and Deep Learning: Algorithms, Tools, and Applications*. Newark: John Wiley & Sons Incorporated. ISBN: 978-1-119-82125-0.
- Singh, Pramod (2021). „Model Deployment and Challenges“. In: *Deploy Machine Learning Models to Production*. Hrsg. von Pramod Singh. Berkeley: Apress, S. 55–66. ISBN: 978-1-4842-6545-1. DOI: 10.1007/978-1-4842-6546-8.
- Singla, Amandeep (2023). „Machine Learning Operations (MLOps): Challenges and Strategies“. In: *Journal of Knowledge Learning and Science Technology* 2.3, S. 333–340. DOI: 10.60087/jklst.vol2.n3.p340.
- Smit, Werner A.; Christiaan Lamprecht (2023). „A Control Risk Template to address the risks with the implementation of prescriptive analytics“. In: *South African Journal of Business Management* 55.1. DOI: 10.4102/sajbm.v55i1.4708.
- So, Albert (2019). „Motor Drive and Control“. In: *Elevator World*.
- Sobot, Tamara; Vladimir Stankovic; Lina Stankovic (2024). „Human in the loop active learning for time-series electrical measurement data“. In: *Engineering Applications of Artificial Intelligence* 133. DOI: 10.1016/j.engappai.2024.108589.
- Soda, Seiichi (1994). „Cross-bar cup feed transfer press for automotive application“. In: *Journal of Materials Processing Technology* 46.3-4, S. 401–407. DOI: 10.1016/0924-0136(94)90123-6.
- Soder, Johann (2014). „Use Case Production: Von CIM über Lean Production zu Industrie 4.0“. In: *Industrie 4.0 in Produktion, Automatisierung und Logistik*. Hrsg. von Thomas Bauernhansl; Michael ten Hompel; Birgit Vogel-Heuser. Wiesbaden: Springer Fachmedien Wiesbaden, S. 85–102. ISBN: 978-3-658-04681-1. DOI: 10.1007/978-3-658-04682-8_4.

- Sokolova, Marina; Guy Lapalme (2009). „A systematic analysis of performance measures for classification tasks“. In: *Information Processing & Management* 45.4, S. 427–437. DOI: 10.1016/j.ipm.2009.03.002.
- Song, Sukho; Dirk-Michael Drotlef; Donghoon Son; Anastasia Koivikko; Metin Sitti (2021). „Adaptive Self-Sealing Suction-Based Soft Robotic Gripper“. In: *Advanced science (Weinheim, Baden-Wurttemberg, Germany)* 8.17, e2100641. DOI: 10.1002/advs.202100641.
- Soni, Ruchi (2023). „Continuous Data Pipelines“. In: *Snowflake SnowPro™ Advanced Architect Certification Companion*. Hrsg. von Ruchi Soni. Certification Study Companion Series. Berkeley: Apress, S. 149–162. ISBN: 978-1-4842-9261-7. DOI: 10.1007/978-1-4842-9262-4_12.
- Sonnenberg, Christian; Jan vom Brocke (2012). „Evaluation Patterns for Design Science Research Artefacts“. In: *Practical Aspects of Design Science*. Hrsg. von Markus Helfert; Brian Donnellan. Bd. 286. Communications in Computer and Information Science. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 71–83. ISBN: 978-3-642-33680-5. DOI: 10.1007/978-3-642-33681-2_7.
- Sossenheimer, Johannes; Jessica Walther; Jan Fleddermann; Eberhard Abele (2019). „A Sensor Reduced Machine Learning Approach for Condition-based Energy Monitoring for Machine Tools“. In: *Procedia CIRP* 81, S. 570–575. DOI: 10.1016/j.procir.2019.03.157.
- Souibgui, Manel; Faten Atigui; Saloua Zammali; Samira Cherfi; Sadok Ben Yahia (2019). „Data quality in ETL process: A preliminary study“. In: *Procedia Computer Science* 159, S. 676–687. DOI: 10.1016/j.procs.2019.09.223.
- Soumaya, OUNACER; TALHAOU Mohamed Amine; Ardchird Soufiane; DAIF Abderrahmane; AZOUAZI Mohamed (2017). „Real-time Data Stream Processing - Challenges and Perspectives“. In: *International Journal of Computer Science Issues* 14.5, S. 6–12. DOI: 10.20943/01201705.612.
- Souza, Josiely Borges de; Sandra Mara Santana Rocha (2024). „PRESCRIPTIVE MAINTENANCE SYNCHRONIZED TO THE CHARACTERISTICS OF INDUSTRY 5.0: A THEORETICAL DISCUSSION“. In: *Journal of Technology and Operations Management* 19.1, S. 40–58. DOI: 10.32890/jtom2024.19.1.4.
- Spendla, Lukas; Michal Kebisek; Pavol Tanuska; Lukas Hrcka (2017). „Concept of predictive maintenance of production systems in accordance with industry 4.0“. In: *2017 IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMI)*. IEEE, S. 000405–000410. ISBN: 978-1-5090-5655-2. DOI: 10.1109/SAMI.2017.7880343.
- Sperandei, Sandro (2014). „Understanding logistic regression analysis“. In: *Biochimica medica* 24.1, S. 12–18. DOI: 10.11613/BM.2014.003.
- Spexet, AnnMarie; Jessica LaRocco-Olszewski; David Alvord (2023). „Data Pipeline Considerations for Aviation Maintenance“. In: *2023 IEEE Aerospace Conference*. IEEE, S. 1–7. ISBN: 978-1-6654-9032-0. DOI: 10.1109/AERO55745.2023.10115656.
- Sreemathy, J; Infant Joseph V; S Nisha; Chaaru Prabha I; Gokula Priya RM (2020). „Data Integration in ETL Using TALEND“. In: *2020 6th International Conference on*

- Advanced Computing and Communication Systems (ICACCS)*. IEEE, S. 1444–1448. ISBN: 978-1-7281-5196-0. DOI: 10.1109/ICACCS48705.2020.9074186.
- Sreemathy, J; K Naveen Durai; E Lakshmi Priya; R Deebika; K Suganthi; PT Aisshwarya (2021). „Data Integration and ETL: A Theoretical Perspective“. In: *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*. IEEE, S. 1655–1660. ISBN: 978-1-6654-0520-1. DOI: 10.1109/ICACCS51430.2021.9441997.
- Srinath, KR (2017). „Python–The Fastest Growing Programming Language“. In: *International Research Journal of Engineering and Technology (IRJET)* 4, S. 354–357.
- Srivastava, Praveen Ranjan; Parshad Patel; Siddharth Chatrola (2009). „Cause effect graph to decision table generation“. In: *ACM SIGSOFT Software Engineering Notes* 34.2, S. 1–4. DOI: 10.1145/1507195.1507216.
- Stanula, Patrick; Amina Ziegenbein; Joachim Metternich (2018). „Machine learning algorithms in production: A guideline for efficient data source selection“. In: *Procedia CIRP* 78. 6th CIRP Global Web Conference – Envisaging the future manufacturing, design, technologies and systems in innovation era (CIRPe 2018), S. 261–266. DOI: 10.1016/j.procir.2018.08.177.
- Steenbuck, Johannes; Fabian Hönl; Safa Evirgen (2023). „Vorrichtung und Verfahren zur Vorhersage des Zustands von mindestens einer Systemkomponente einer zyklisch produzierenden Anlage“. WO 2023/020644 A1. URL: <https://depatisnet.dpma.de/DepatisNet/depatisnet?action=bibdat&docid=W0002023020644A1>.
- Steinle, Lukas; Armin Lechler; Michael Neubauer; Alexander Verl (2022). „Experimental investigation into the implications of transmission errors for rack-and-pinion drives“. In: *Production Engineering* 16.4, S. 453–463. DOI: 10.1007/s11740-021-01090-y.
- Stockinger, Kurt; Thilo Stadelmann; Andreas Ruckstuhl (2016). „Data Scientist als Beruf“. In: *Big Data*. Hrsg. von Daniel Fasel; Andreas Meier. Edition HMD. Wiesbaden: Springer Fachmedien Wiesbaden, S. 59–81. ISBN: 978-3-658-11588-3. DOI: 10.1007/978-3-658-11589-0_4.
- Storr, Alfred; Stefan Angermüller; Joachim Dreyer (2001). „Informationsmodellierung für die technische Dokumentation“. In: *Zeitschrift für wirtschaftlichen Fabrikbetrieb* 96.10, S. 559–565. DOI: 10.3139/104.100484.
- Strunz, Matthias (2012). *Instandhaltung: Grundlagen - Strategien - Werkstätten*. Berlin und Heidelberg: Springer Vieweg. ISBN: 978-3-642-27389-6.
- Sturm, Silke (2021). „Textdaten“. In: *Neuermessung der Datenökonomie*. Hrsg. von Thomas Straubhaar; Zahurul Islam; Deniz Dilan Karaman Örsal; Christina Heike Maass; Felix Roth; Niklas Scheffer; Henrique Schneider; Silke Sturm; Henning Vöpel. Bd. 6. Edition HWWI. Hamburg University Press, publishing house of the Hamburg State and University Library, S. 129–156. ISBN: 978-3-943423-91-4. DOI: 10.15460/hup.254.1927.
- Su, Xiaogang; Xin Yan; Chih-Ling Tsai (2012). „Linear regression“. In: *WIREs Computational Statistics* 4.3, S. 275–294. DOI: 10.1002/wics.1198.
- Suchánek, Petr; Franciszek Marecki; Robert Bucki; Eva Litavcová (2021). „Logistic Optimization of the Production Centre“. In: *International Journal of Applied Mathematics, Computational Science and Systems Engineering* 3.

- Sundermeyer, Martin; Tamer Alkhoul; Joern Wuebker; Hermann Ney (2014). „Translation modeling with bidirectional recurrent neural networks“. In: *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*, S. 14–25.
- Susana Ferreira; Egoitz Konde; Santiago Fernández; Agustín Prado (2016). „INDUSTRY 4.0: Predictive Intelligent Maintenance for Production Equipment“. In: *PHM Society European Conference 3.1*. DOI: 10.36001/phme.2016.v3i1.1667.
- Süve, Mustafa Furkan; Cengiz Gezer; Gökhan İnce (2022). „Predictive Maintenance Framework for Production Environments Using Digital Twin“. In: *Intelligent and Fuzzy Techniques for Emerging Conditions and Digital Transformation*. Hrsg. von Cengiz Kahraman; Selcuk Cebi; Sezi Cevik Onar; Basar Oztaysi; A. Cagri Tolga; Irem Ucal Sari. Bd. 308. Lecture Notes in Networks and Systems. Cham: Springer International Publishing, S. 455–462. ISBN: 978-3-030-85576-5. DOI: 10.1007/978-3-030-85577-2_54.
- Szopinski, Daniel; Thorsten Schoormann; Dennis Kundisch (2020). „Criteria as a Prelude for Guiding Taxonomy Evaluation“. In: *Proceedings of the 53rd Hawaii International Conference on System Sciences*. Hrsg. von Tung Bui. Proceedings of the Annual Hawaii International Conference on System Sciences. Hawaii International Conference on System Sciences. DOI: 10.24251/HICSS.2020.622.
- Taheri, Javid; Shahram Dustdar; Albert Zomaya; Shuiguang Deng (2023). „AI/ML Data Pipelines for Edge-Cloud Architectures“. In: *Edge Intelligence*. Hrsg. von Javid Taheri; Shahram Dustdar; Albert Zomaya; Shuiguang Deng. Cham: Springer International Publishing, S. 159–181. ISBN: 978-3-031-22154-5. DOI: 10.1007/978-3-031-22155-2_5.
- Tahir, Hassane; Patrick Brezillon (2011). „A shared context approach for supporting experts in data ETL (Extraction, Transformation and Loading) processes“. In: *2011 11th International Conference on Intelligent Systems Design and Applications*. IEEE, S. 720–725. ISBN: 978-1-4577-1676-8. DOI: 10.1109/ISDA.2011.6121741.
- Tamir, Mike; Steven Miller (2015). „The Data Engineer“. In: *SSRN Electronic Journal*. DOI: 10.2139/ssrn.2762013.
- Taniar, David; Wenny Rahayu (2021). „Data Lake Architecture“. In: *Advances in Internet, Data and Web Technologies*. Hrsg. von Leonard Barolli; Juggapong Natwichai; Tomoya Enokido. Bd. 65. Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer International Publishing, S. 344–357. ISBN: 978-3-030-70638-8. DOI: 10.1007/978-3-030-70639-5_32.
- Tarafdar, Rajarshi (2025). „An Automated Approach to Model Deployment Maintenance and Reliability“. In: *International Journal of Information Technology and Management Information Systems* 16.1, S. 992–1004. DOI: 10.34218/IJITMIS_16_01_071.
- Tardio, Roberto; Alejandro Mate; Juan Trujillo (2020). „An Iterative Methodology for Defining Big Data Analytics Architectures“. In: *IEEE Access* 8, S. 210597–210616. DOI: 10.1109/ACCESS.2020.3039455.
- Tatachar, Abhishek V (2021). „Comparative assessment of regression models based on model evaluation metrics“. In: *International Research Journal of Engineering and Technology (IRJET)* 8.09.

- Tetko, Igor V.; Ruud van Deursen; Guillaume Godin (2024). „Be aware of overfitting by hyperparameter optimization!“ In: *Journal of cheminformatics* 16.1, S. 139. DOI: 10.1186/s13321-024-00934-w.
- Thantilage, Ranul D.; Nhien-An Le-Khac; M-Tahar Kechadi (2023). „Healthcare data security and privacy in Data Warehouse architectures“. In: *Informatics in Medicine Unlocked* 39, S. 101270. DOI: 10.1016/j.imu.2023.101270.
- Theodoratos, Dimitri; Timos Sellis (1997). „Data warehouse configuration“. In: *Proceedings of the 23rd International Conference on Very Large Databases, VLDB 1997*. Morgan Kaufmann, S. 126–135.
- Thornton, Chris; Frank Hutter; Holger H. Hoos; Kevin Leyton-Brown (2013). „AutoWEKA“. In: *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*. Hrsg. von Rayid Ghani; Ted E. Senator; Paul Bradley; Rajesh Parekh; Jingrui He; Robert L. Grossman; Ramasamy Uthrusamy; Inderjit S. Dhillon; Yehuda Koren. New York: ACM, S. 847–855. ISBN: 9781450321747. DOI: 10.1145/2487575.2487629.
- Tononi, G (2010). „Information integration: its relevance to brain function and consciousness“. In: *Archives italiennes de biologie* 148.3, S. 299–322.
- Torraco, Richard J. (2005). „Writing Integrative Literature Reviews: Guidelines and Examples“. In: *Human Resource Development Review* 4.3, S. 356–367. DOI: 10.1177/1534484305278283.
- Triguero, Isaac; Diego García-Gil; Jesús Maillo; Julián Luengo; Salvador García; Francisco Herrera (2019). „Transforming big data into smart data: An insight on the use of the k-nearest neighbors algorithm to obtain quality data“. In: *WIREs Data Mining and Knowledge Discovery* 9.2. DOI: 10.1002/widm.1289.
- Tu, Doan Quang; A. S. M. Kayes; Wenny Rahayu; Kinh Nguyen (2020). „IoT streaming data integration from multiple sources“. In: *Computing* 102.10, S. 2299–2329. DOI: 10.1007/s00607-020-00830-9.
- Uhlemann, Thomas H.-J.; Christian Lehmann; Rolf Steinhilper (2017). „The Digital Twin: Realizing the Cyber-Physical Production System for Industry 4.0“. In: *Procedia CIRP* 61, S. 335–340. DOI: 10.1016/j.procir.2016.11.152.
- Uhlmann, Eckart; Julian Polte; Nikolaos-Stefanos Koutrakis (2021). „Holistic Concept Towards a Reference Architecture Model for Predictive Maintenance“. In: *Procedia CIRP* 104, S. 1430–1433. DOI: 10.1016/j.procir.2021.11.241.
- Um, Seunghwan; Heeyeon Jeong; Chun Soo Kim; Issac Rhee; Hyouk Ryeol Choi (2024). „ReC-Gripper: A Reconfigurable Combined Suction and Fingered Gripper for Various Logistics Picking and Stowing Tasks“. In: *IEEE Robotics and Automation Letters* 9.1, S. 87–94. DOI: 10.1109/LRA.2023.3330051.
- Vaduva, Anca; Thomas Vetterli (2001). „METADATA MANAGEMENT FOR DATA WAREHOUSING: AN OVERVIEW“. In: *International Journal of Cooperative Information Systems* 10.03, S. 273–298. DOI: 10.1142/S0218843001000357.
- Vaisman, Alejandro; Esteban Zimányi (2022). „Introduction“. In: *Data Warehouse Systems*. Hrsg. von Alejandro Vaisman; Esteban Zimányi. Data-Centric Systems and Applicati-

- ons. Berlin und Heidelberg: Springer Berlin Heidelberg, S. 3–10. ISBN: 978-3-662-65166-7. DOI: 10.1007/978-3-662-65167-4_1.
- van Aken, Joan (2014). „Two Hurdles to Take for Maximum Impact of Design Science Research in the IS-Field“. In: *Design Science: Perspectives from Europe*. Hrsg. von Markus Helfert; Brian Donnellan; Jim Kenneally. Bd. 447. Communications in Computer and Information Science. Cham: Springer International Publishing, S. 28–40. ISBN: 978-3-319-13935-7. DOI: 10.1007/978-3-319-13936-4_3.
- van Aken, Joan; Aravind Chandrasekaran; Joop Halman (2016). „Conducting and publishing design science research“. In: *Journal of Operations Management* 47-48.1, S. 1–8. DOI: 10.1016/j.jom.2016.06.004.
- van Beers, Floris; Arvid Lindström; Emmanuel Okafor; Marco Wiering (2019). „Deep Neural Networks with Intersection over Union Loss for Binary Image Segmentation“. In: *Proceedings of the 8th International Conference on Pattern Recognition Applications and Methods*. SCITEPRESS - Science and Technology Publications, S. 438–445. ISBN: 978-989-758-351-3. DOI: 10.5220/0007347504380445.
- van der Weide, Tom; Dimitris Papadopoulos; Oleg Smirnov; Michal Zielinski; Tim van Kasteren (2017). „Versioning for End-to-End Machine Learning Pipelines“. In: *Proceedings of the 1st Workshop on Data Management for End-to-End Machine Learning*. New York: ACM, S. 1–9. ISBN: 9781450350266. DOI: 10.1145/3076246.3076248.
- van Dinter, Raymon; Bedir Tekinerdogan; Cagatay Catal (2023). „Reference architecture for digital twin-based predictive maintenance systems“. In: *Computers & Industrial Engineering* 177, S. 109099. DOI: 10.1016/j.cie.2023.109099.
- van Horenbeek, Adriaan; Liliane Pintelon; Abdellatif Bey-Temsamani; Andrei Bartic (2014). „Multi-objective optimization of OEE (Overall Equipment Effectiveness) regarding production speed and energy consumption“. In: *PHM Society European Conference* 2.1. DOI: 10.36001/phme.2014.v2i1.1525.
- van Houdt, Greg; Carlos Mosquera; Gonzalo Nápoles (2020). „A review on the long short-term memory model“. In: *Artificial Intelligence Review* 53.8, S. 5929–5955. DOI: 10.1007/s10462-020-09838-1.
- Vassiliadis, Panos; Alkis Simitsis; Spiros Skiadopoulos (2002). „Conceptual modeling for ETL processes“. In: *Proceedings of the 5th ACM international workshop on Data Warehousing and OLAP*. Hrsg. von Il-Yeol Song; Dimitri Theodoratos. New York: ACM, S. 14–21. ISBN: 1581135904. DOI: 10.1145/583890.583893.
- Vater, Johannes; Pascal Schlaak; Alois Knoll (2020). „A Modular Edge-/Cloud-Solution for Automated Error Detection of Industrial Hairpin Weldings using Convolutional Neural Networks“. In: *2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC)*. IEEE, S. 505–510. ISBN: 978-1-7281-7303-0. DOI: 10.1109/COMPSAC48688.2020.0-202.
- Veichtlbauer, Armin; Martin Ortmayr; Thomas Heistracher (2017). „OPC UA integration for field devices“. In: *2017 IEEE 15th International Conference on Industrial Informatics (INDIN)*. IEEE, S. 419–424. ISBN: 978-1-5386-0837-1. DOI: 10.1109/INDIN.2017.8104808.

- Velmurugan, Rama Srinivasan; Tarun Dhingra (2021). „Asset Maintenance in Operations-Intensive Organizations“. In: *Asset Maintenance Management in Industry: A Comprehensive Guide to Strategies, Practices and Benchmarking*. Bd. 310. Cham: Springer International Publishing, S. 23–59. DOI: 10.1007/978-3-030-74154-9_2.
- Verbraeken, Joost; Matthijs Wolting; Jonathan Katzy; Jeroen Kloppenburg; Tim Verbelen; Jan S. Rellermeyer (2021). „A Survey on Distributed Machine Learning“. In: *ACM Computing Surveys* 53.2, S. 1–33. DOI: 10.1145/3377454.
- Verl, A.; T. Engelberth (2018). „Adaptive preloading for rack-and-pinion drive systems“. In: *CIRP Annals* 67.1, S. 369–372. DOI: 10.1016/j.cirp.2018.03.006.
- Vidulin, Vedrana; Marko Bohanec; Matjaž Gams (2014). „Combining human analysis and machine data mining to obtain credible data relations“. In: *Information Sciences* 288, S. 254–278. DOI: 10.1016/j.ins.2014.08.014.
- Vogel-Heuser, B.; V. Karaseva; J. Folmer; I. Kirchen (2017). „Operator Knowledge Inclusion in Data-Mining Approaches for Product Quality Assurance using Cause-Effect Graphs“. In: *IFAC-PapersOnLine* 50.1, S. 1358–1365. DOI: 10.1016/j.ifacol.2017.08.233.
- Vujovic, Željko Đ. (2021). „Classification Model Evaluation Metrics“. In: *International Journal of Advanced Computer Science and Applications* 12.6. DOI: 10.14569/IJACSA.2021.0120670.
- Wagh, Sanjeev J.; Manisha S. Bhende; Anuradha D. Thakare (2021). *Fundamentals of Data Science*. Boca Raton: Chapman and Hall/CRC. ISBN: 9780429443237. DOI: 10.1201/9780429443237.
- Walker, Coral; Hassan Alrehamy (2015). „Personal Data Lake with Data Gravity Pull“. In: *2015 IEEE Fifth International Conference on Big Data and Cloud Computing*. IEEE, S. 160–167. ISBN: 978-1-4673-7183-4. DOI: 10.1109/BDCLOUD.2015.62.
- Walls, Joseph G.; George R. Widmeyer; Omar A. El Sawy (1992). „Building an Information System Design Theory for Vigilant EIS“. In: *Information Systems Research* 3.1, S. 36–59. DOI: 10.1287/isre.3.1.36.
- Wan, Shiuan (2009). „A spatial decision support system for extracting the core factors and thresholds for landslide susceptibility map“. In: *Engineering Geology* 108.3-4, S. 237–251. DOI: 10.1016/j.enggeo.2009.06.014.
- Wang, Hongrui; Alfredo Nunez; Zhigang Liu; Dongliang Zhang; Rolf Dollevoet (2020). „A Bayesian Network Approach for Condition Monitoring of High-Speed Railway Catenaries“. In: *IEEE Transactions on Intelligent Transportation Systems* 21.10, S. 4037–4051. DOI: 10.1109/TITS.2019.2934346.
- Wang, Jingting; Bao Liu (2020). „Design of ETL Tool for Structured Data Based on Data Warehouse“. In: *Proceedings of the 4th International Conference on Computer Science and Application Engineering*. Hrsg. von Ali Emrouznejad; Jui-Sheng Rayson Chou. New York: ACM, S. 1–5. ISBN: 9781450377720. DOI: 10.1145/3424978.3425101.
- Wang, Kesheng; Guohong Dai; Lanzhong Guo (2016). „Intelligent Predictive Maintenance (IPdM) for Elevator Service- Through CPS, IOTaS and Data Mining“. In: *Proceedings of the 6th International Workshop of Advanced Manufacturing and Automation*. Paris: Atlantis Press. ISBN: 978-94-6252-243-5. DOI: 10.2991/iwama-16.2016.1.

- Wang, Qi; Yue Ma; Kun Zhao; Yingjie Tian (2022). „A Comprehensive Survey of Loss Functions in Machine Learning“. In: *Annals of Data Science* 9.2, S. 187–212. DOI: 10.1007/s40745-020-00253-5.
- Wang, Qianwen; Zhutian Chen; Yong Wang; Huamin Qu (2022). „A Survey on ML4VIS: Applying Machine Learning Advances to Data Visualization“. In: *IEEE transactions on visualization and computer graphics* 28.12, S. 5134–5153. DOI: 10.1109/TVCG.2021.3106142.
- Wang, Rui; Yuesheng Xu; Mingsong Yan (2024). „Hypothesis Spaces for Deep Learning“. In: DOI: 10.48550/arXiv.2403.03353.
- Wazirali, Raniyah (2020). „An Improved Intrusion Detection System Based on KNN Hyperparameter Tuning and Cross-Validation“. In: *Arabian Journal for Science and Engineering* 45.12, S. 10859–10873. DOI: 10.1007/s13369-020-04907-7.
- Weber, Felix (2020). *Künstliche Intelligenz für Business Analytics*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-29772-5. DOI: 10.1007/978-3-658-29773-2.
- Wei, Sha; Yuanze Ma; Ruiqi Li; Lin Hu (2020). „Toward Smart Manufacturing: Key Technologies and Trends Driving Standardization“. In: *Computer* 53.4, S. 46–50. DOI: 10.1109/MC.2020.2970821.
- Weihs, C. (1993). „Multivariate exploratory data analysis and graphics: A tutorial“. In: *Journal of Chemometrics* 7.5, S. 305–340. DOI: 10.1002/cem.1180070502.
- Weller, Julian; Nico Migenda; Yash Naik; Tim Heuwinkel; Arno Kühn; Martin Kohlhasse; Wolfram Schenck; Roman Dumitrescu (2024). „Reference Architecture for the Integration of Prescriptive Analytics Use Cases in Smart Factories“. In: *Mathematics* 12.17, S. 2663. DOI: 10.3390/math12172663.
- Wesendrup, Kevin; Bernd Hellingrath; Zoi Nikolarakis (2024). „A framework for conceptualizing integrated prescriptive maintenance and production planning and control models“. In: *Brazilian Journal of Operations & Production Management* 21.3, S. 2172. DOI: 10.14488/BJOPM.2172.2024.
- Wierse, Andreas; Till Riedel (2017). *Smart data analytics: Mit Hilfe von Big Data Zusammenhänge erkennen Potentiale nutzen*. De Gruyter Praxishandbuch. Berlin und Boston: De Gruyter. ISBN: 978-3-11-046184-8.
- Wijaya, Rahmadi; Bambang Pudjoatmodjo (2015). „An overview and implementation of extraction-transformation-loading (ETL) process in data warehouse (Case study: Department of agriculture)“. In: *2015 3rd International Conference on Information and Communication Technology (ICoICT)*. IEEE, S. 70–74. ISBN: 978-1-4799-7752-9. DOI: 10.1109/ICoICT.2015.7231399.
- Williams, Will; Niranjani Prasad; David Mrva; Tom Ash; Tony Robinson (2015). „Scaling recurrent neural network language models“. In: *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, S. 5391–5395. ISBN: 978-1-4673-6997-8. DOI: 10.1109/ICASSP.2015.7179001.
- Wilson, Ashia C; Rebecca Roelofs; Mitchell Stern; Nati Srebro; Benjamin Recht (2017). „The Marginal Value of Adaptive Gradient Methods in Machine Learning“. In: *Advances in Neural Information Processing Systems*. Hrsg. von I. Guyon; U. Von Luxburg;

- S. Bengio; H. Wallach; R. Fergus; S. Vishwanathan; R. Garnett. Bd. 30. Curran Associates, Inc.
- Winkens, M.; M. Schmidt; P. Nyhuis (2015). „Zustandsorientierte Instandhaltung*/Condition-based maintenance“. In: *wt Werkstattstechnik online* 105.03, S. 104–108. DOI: 10.37544/1436-4980-2015-03-28.
- Wirth, Rüdiger; Jochen Hipp (2000). „Crisp-dm: towards a standard process modell for data mining“. In: S. 29–40. URL: <https://api.semanticscholar.org/CorpusID:1211505>.
- Wollschlaeger, Martin; Stefan Theurich; Albrecht Winter; Frank Lubnau; Christoph Paulitsch (2015). „A reference architecture for condition monitoring“. In: *2015 IEEE World Conference on Factory Communication Systems (WFCS)*. IEEE, S. 1–8. ISBN: 978-1-4799-8244-8. DOI: 10.1109/WFCS.2015.7160555.
- Wootton, Dylan; Amy Rae Fox; Evan Peck; Arvind Satyanarayan (2025). „Charting EDA: Characterizing Interactive Visualization Use in Computational Notebooks with a Mixed-Methods Formalism“. In: *IEEE transactions on visualization and computer graphics* 31.1, S. 1191–1201. DOI: 10.1109/TVCG.2024.3456217.
- Wu, Dingming; Xiaolong Wang; Jingyong Su; Buzhou Tang; Shaocong Wu (2020). „A Labeling Method for Financial Time Series Prediction Based on Trends“. In: *Entropy (Basel, Switzerland)* 22.10. DOI: 10.3390/e22101162.
- Wu, Jianxin (2017). „Introduction to convolutional neural networks“. In: *National Key Lab for Novel Software Technology. Nanjing University. China* 5.23.
- Wu, Sze-jung; Nagi Gebraeel; Mark A. Lawley; Yuehwen Yih (2007). „A Neural Network Integrated Decision Support System for Condition-Based Optimal Predictive Maintenance Policy“. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 37.2, S. 226–236. DOI: 10.1109/TSMCA.2006.886368.
- Xanthopoulos, Petros; Panos M. Pardalos; Theodore B. Trafalis (2013). *Robust Data Mining*. New York: Springer New York. ISBN: 978-1-4419-9877-4. DOI: 10.1007/978-1-4419-9878-1.
- Xiao, Bo; Chaolin Zhang; Yici Mao; Guohui Qian (2015). „Review and exploration of metadata management in data warehouse“. In: *2015 IEEE 10th Conference on Industrial Electronics and Applications (ICIEA)*. IEEE, S. 928–933. ISBN: 978-1-4799-8389-6. DOI: 10.1109/ICIEA.2015.7334243.
- Xu, Gaowei; Min Liu; Jingwei Wang; Yumin Ma; Jian Wang; Fei Li; Weiming Shen (2019). „Data-Driven Fault Diagnostics and Prognostics for Predictive Maintenance: A Brief Overview“. In: *2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)*. IEEE, S. 103–108. ISBN: 978-1-7281-0356-3. DOI: 10.1109/COASE.2019.8843068.
- Xu, Peng; Gokop L. Goteng; Yu He (2021). „Modelling cloud service latency and availability using a deep learning strategy“. In: *Expert Systems with Applications* 182, S. 115121. DOI: 10.1016/j.eswa.2021.115121.
- Xu, Yun; Royston Goodacre (2018). „On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating

- the Generalization Performance of Supervised Learning“. In: *Journal of analysis and testing* 2.3, S. 249–262. DOI: 10.1007/s41664-018-0068-2.
- Yan, Jiangqiao; Hongqi Wang; Menglong Yan; Wenhui Diao; Xian Sun; Hao Li (2019). „IoU-Adaptive Deformable R-CNN: Make Full Use of IoU for Multi-Class Object Detection in Remote Sensing Imagery“. In: *Remote Sensing* 11.3, S. 286. DOI: 10.3390/rs11030286.
- Yang, Wenli; Rui Fu; Muhammad Bilal Amin; Byeong Kang (2025). „The Impact of Modern AI in Metadata Management“. In: *Human-Centric Intelligent Systems*. DOI: 10.1007/s44230-025-00106-5.
- Yessad, Lamia; Aissa Labiod (2016). „Comparative study of data warehouses modeling approaches: Inmon, Kimball and Data Vault“. In: *2016 International Conference on System Reliability and Science (ICSRS)*. IEEE, S. 95–99. ISBN: 978-1-5090-3277-8. DOI: 10.1109/ICSRS.2016.7815845.
- Yigitbasioglu, Ogan M.; Oana Velcu (2012). „A review of dashboards in performance management: Implications for design and research“. In: *International Journal of Accounting Information Systems* 13.1, S. 41–59. DOI: 10.1016/j.accinf.2011.08.002.
- Yin, Robert K. (1993). *Applications of case study research*. Bd. 34. Applied social research methods series. Newbury Park: Sage Publ. ISBN: 0-8039-5118-3.
- (2009). *Case study research: Design and methods*. 4. Aufl. Bd. vol. 5. Applied social research methods series. Los Angeles: SAGE Publications. ISBN: 9781412960991.
- (2014). *Case study research: Design and methods*. 5. Aufl. Los Angeles u. a.: SAGE. ISBN: 978-1-4522-4256-9.
- Ying, Xue (2019). „An Overview of Overfitting and its Solutions“. In: *Journal of Physics: Conference Series* 1168, S. 022022. DOI: 10.1088/1742-6596/1168/2/022022.
- You, Xinya; David Hands (2019). „A Reflection upon Herbert Simon’s Vision of Design in The Sciences of the Artificial“. In: *The Design Journal* 22.sup1, S. 1345–1356. DOI: 10.1080/14606925.2019.1594961.
- Yu, Shidong; Liguang Deng; Yong Zhang (2009). „Visualization User Interface for Decision Support Systems“. In: *2009 Ninth International Conference on Hybrid Intelligent Systems*. IEEE, S. 63–66. ISBN: 978-0-7695-3745-0. DOI: 10.1109/HIS.2009.20.
- Zacher, Serge (2021). *Regelungstechnik mit Data Stream Management*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-30859-9. DOI: 10.1007/978-3-658-30860-5.
- Zachman, J. A. (1987). „A framework for information systems architecture“. In: *IBM Systems Journal* 26.3, S. 276–292. DOI: 10.1147/sj.263.0276.
- Zagan, Elisabeta; Mirela Danubianu (2020). „Data Lake Approaches: A Survey“. In: *2020 International Conference on Development and Application Systems (DAS)*. IEEE, S. 189–193. ISBN: 978-1-7281-6870-8. DOI: 10.1109/DAS49615.2020.9108912.
- Zakoldaev, D. A.; A. V. Gurjanov; I. O. Zharinov; O. O. Zharinov (2019). „Centralized, decentralized, hybrid principles of cyber-physical systems control of the Industry 4.0“. In: *Journal of Physics: Conference Series* 1353.1, S. 012143. DOI: 10.1088/1742-6596/1353/1/012143.
- Zekveld, M.; G. P. Hancke (2018). „Vibration Condition Monitoring Using Machine Learning“. In: *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics*

- Society*. IEEE, S. 4742–4747. ISBN: 978-1-5090-6684-1. DOI: 10.1109/IECON.2018.8591167.
- Zenisek, Jan; Florian Holzinger; Michael Affenzeller (2019). „Machine learning based concept drift detection for predictive maintenance“. In: *Computers & Industrial Engineering* 137, S. 106031. DOI: 10.1016/j.cie.2019.106031.
- Zenkert, Johannes; Christian Weber; Mareike Dornhöfer; Hasan Abu-Rasheed; Madjid Fathi (2021). „Knowledge Integration in Smart Factories“. In: *Encyclopedia* 1.3, S. 792–811. DOI: 10.3390/encyclopedia1030061.
- Zhai, Simon; Alexander Riess; Gunther Reinhart (2019). „Formulation and Solution for the Predictive Maintenance Integrated Job Shop Scheduling Problem“. In: *2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*. IEEE, S. 1–8. ISBN: 978-1-5386-8357-6. DOI: 10.1109/ICPHM.2019.8819397.
- Zhai, Yiteng; Yew-Soon Ong; Ivor W. Tsang (2014). „The Emerging Big Dimensionality“. In: *IEEE Computational Intelligence Magazine* 9.3, S. 14–26. DOI: 10.1109/MCI.2014.2326099.
- Zhai, Zhaoyu; José Fernán Martínez; Victoria Beltran; Néstor Lucas Martínez (2020). „Decision support systems for agriculture 4.0: Survey and challenges“. In: *Computers and Electronics in Agriculture* 170, S. 105256. DOI: 10.1016/j.compag.2020.105256.
- Zhang, Chuan; Liwei Cao; Alessandro Romagnoli (2018). „On the feature engineering of building energy data mining“. In: *Sustainable Cities and Society* 39, S. 508–518. DOI: 10.1016/j.scs.2018.02.016.
- Zhang, Jieyu; Cheng-Yu Hsieh; Yue Yu; Chao Zhang; Alexander Ratner (2022). „A Survey on Programmatic Weak Supervision“. In: DOI: 10.48550/arXiv.2202.05433.
- Zhang, Weiting; Dong Yang; Hongchao Wang (2019). „Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey“. In: *IEEE Systems Journal* 13.3, S. 2213–2227. DOI: 10.1109/JSYST.2019.2905565.
- Zhang, Yagang (2010). *New Advances in Machine Learning*. InTech. ISBN: 978-953-307-034-6. DOI: 10.5772/225.
- Zhang, Zhongheng (2016). „Introduction to machine learning: k-nearest neighbors“. In: *Annals of translational medicine* 4.11, S. 218. DOI: 10.21037/atm.2016.03.37.
- Zheng, QiuHong; Jinghan Wang; Yun Shen (2024). „Overview and Trend of Large-scale Model Deployment Mode“. In: *2024 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*. IEEE, S. 1–6. ISBN: 979-8-3503-6426-2. DOI: 10.1109/BMSB62888.2024.10608242.
- Zhong, Dong; Zhelei Xia; Yian Zhu; Junhua Duan (2023). „Overview of predictive maintenance based on digital twin technology“. In: *Heliyon* 9.4, e14534. DOI: 10.1016/j.heliyon.2023.e14534.
- Zhukov, Vlad; Eugene Golikov; Maksim KretoV (2017). „Differentiable lower bound for expected BLEU score“. In: DOI: 10.48550/arXiv.1712.04708.
- Zohrevandi, Elmira; Katerina Vrotsou; Carl A. L. Westin; Jonas Lundberg; Anders Ynnerman (2024). „Design of a Real-Time Visual Analytics Decision Support Interface to Ma-

- nage Air Traffic Complexity“. In: *2024 IEEE Visualization and Visual Analytics (VIS)*. IEEE, S. 301–305. ISBN: 979-8-3503-5485-0. DOI: 10.1109/VIS55277.2024.00068.
- Zorn, Ted; Nittaya Campbell (2006). „Improving The Writing Of Literature Reviews Through A Literature Integration Exercise“. In: *Business Communication Quarterly* 69.2, S. 172–183. DOI: 10.1177/1080569906287960.
- Zuckarelli, Joachim L. (2021). *Programmieren lernen mit Python und JavaScript*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-29849-4. DOI: 10.1007/978-3-658-29850-0.
- Zunino, Claudio; Gianluca Cena; Stefano Scanzio; Adriano Valenzano (2021). „Experimental Characterization of Asynchronous Notification Latency for Subscriptions in OPC UA“. In: *2021 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. IEEE, S. 01–08. ISBN: 978-1-7281-2989-1. DOI: 10.1109/ETFA45728.2021.9613502.
- zur Heiden, Philipp; Sascha Kaltenpoth (2024). „Wissensmanagement für Wartung und Instandhaltung im Verteilnetz – Konzeption eines Assistenzsystems basierend auf einem Large Language Model“. In: *HMD Praxis der Wirtschaftsinformatik* 61.4, S. 911–926. DOI: 10.1365/s40702-024-01074-3.

A Algorithmische Grundlagen

Tabelle 17: Übersicht wichtiger Leistungsmetriken

Metrik	Beschreibung	Mathematische Formel
Mean Squared Error (MSE)	Durchschnitt der quadrierten Abweichungen zwischen vorhergesagten und tatsächlichen Werten; misst die Genauigkeit von Regressionsmodellen.	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
Mean Absolute Error (MAE)	Durchschnitt der absoluten Abweichungen zwischen vorhergesagten und tatsächlichen Werten; robust gegenüber Ausreißern.	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Bestimmtheitsmaß (R^2)	Anteil der Varianz der Zielvariable, der durch das Modell erklärt wird.	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$
Accuracy	Anteil der korrekt klassifizierten Instanzen an allen Instanzen.	$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$
Precision	Anteil der korrekt positiven Vorhersagen an allen als positiv vorhergesagten Instanzen.	$Precision = \frac{TP}{TP+FP}$
Recall (Sensitivität)	Anteil der korrekt positiven Vorhersagen an allen tatsächlich positiven Instanzen.	$Recall = \frac{TP}{TP+FN}$
F1-Score	Harmonisches Mittel aus Precision und Recall; nützlich bei unbalancierten Datensätzen.	$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$
ROC-AUC	Fläche unter der ROC-Kurve; misst die Trennschärfe des Modells zwischen Klassen.	$AUC = \int_0^1 TPR(FPR^{-1}(x)) dx$
Top-K-Accuracy	Anteil der Instanzen, bei denen die wahre Klasse unter den Top-K vorhergesagten Klassen liegt.	$TopKAcc = \frac{1}{n} \sum_{i=1}^n \mathbb{1} \left\{ y_i \in \hat{Y}_i^{(K)} \right\}$
Intersection over Union (IoU)	Überlappingsmaß zwischen vorhergesagtem und tatsächlichem Segment bei Objekterkennung.	$IoU = \frac{ B_{pred} \cap B_{true} }{ B_{pred} \cup B_{true} }$
Perplexity	Exponent des mittleren negativen Log-Likelihoods; gebräuchlich in der Sprachmodellierung.	$Perplexity = \exp \left(-\frac{1}{N} \sum_{i=1}^N \log p(w_i) \right)$
BLEU-Score	Bewertet maschinelle Übersetzungen anhand von n-Gramm-Übereinstimmungen mit Referenztexten.	$BLEU = BP \cdot \exp \left(\sum_{n=1}^N w_n \log p_n \right)$

n : Anzahl der Beobachtungen; y_i : wahrer Wert; $\hat{y}_i$: vorhergesagter Wert; $\bar{y}$: Mittelwert der Zielvariable; TP : True Positives; TN : True Negatives; FP : False Positives; FN : False Negatives; TPR : True Positive Rate; FPR : False Positive Rate; $\hat{Y}_i^{(K)}$: Menge der Top-K vorhergesagten Klassen; B_{pred} : vorhergesagter Bereich; B_{true} : tatsächlicher Bereich; $p(w_i)$: Wahrscheinlichkeit des Wortes w_i ; BP : Brevity Penalty; p_n : Präzision für n-Gramme; w_n : Gewichtung des n-Gramms.

Tabelle 18: Überblick über ausgewählte Supervised Learning Modelle

Methode	Anwendungsgebiet	Vorteile	Nachteile	Mögliche Metriken	Quelle
Lineare Regression	Regressionsprobleme, ökonomische Vorhersagen	Einfach, interpretierbar, geringe Kosten	Nur lineare Zusammenhänge abbildbar, empfindlich gegenüber Ausreißern	MSE, MAE, R^2	[vgl. Pradeep Singh 2022, S.5-8; Su et al. 2012, S.275-280; James et al. 2023, S.72-74; Plevris et al. 2022, S.10-11; Tatachar 2021, S.854; Dumre et al. 2024, S.1858-1859]
Logistische Regression	Binäre und multiklassige Klassifikation	Einfach, interpretierbar, probabilistische Ausgaben	Limitiert bei stark nichtlinearen Zusammenhängen	Accuracy, Precision, Recall, ROC-AUC	[vgl. LaValley 2008, S.2395-2396; Nick und K. M. Campbell 2007, S.273-274; Acito 2023a, S.296-297; Kirasich et al. 2018, S.12-15; Muschelli 2020, S.696-697]
Entscheidungsbäume	Klassifikation, Regression	Intuitiv interpretierbar, kann nichtlineare Interaktionen erfassen	Hohe Anfälligkeit für Overfitting	Accuracy, Precision, Recall, F1-Score, ROC-AUC	[vgl. Knuth 2021, S.364-366; Weber 2020, S.50; Charbuty und Abdulazeez 2021, S.21-22; Bramer 2020, S.121; Patil et al. o.D., S.27; Miao und Zhu 2022, S.1547-1548; Demirović und Stuckey 2021, S.3733-3734]
Random Forest	Klassifikation, Regression	Robust, reduziert Overfitting durch Bagging	Weniger interpretierbar, rechenintensiv	Accuracy, Precision, Recall, ROC-AUC, MSE	[vgl. Salman et al. 2024, S.72-74; Parmar et al. 2019, S.760-761; Altman und Krzywinski 2017, S.933; Biau und Scorenet 2016, S.222; Chicco et al. 2021, S.16-17]

Tabelle 18: Überblick über ausgewählte Supervised Learning Modelle

Methode	Anwendungsgebiet	Vorteile	Nachteile	Mögliche Metriken	Quelle
Gradient Boosting	Klassifikation, Regression	Hohe Genauigkeit, hohe Eignung bei strukturierten Daten	Empfindlich gegenüber Rauschen, Tuning aufwendig	Accuracy, ROC-AUC, MSE, MAE	[vgl. Natekin und Knoll 2013, S.1-4; Bertejac et al. 2021, S.1940-1946; Eisenbürger et al. 2024, S.1-2; Freeman et al. 2016, S.326-327; Shafiei et al. 2023, S.5; Sibindi et al. 2023, S.9-10]
Support Vector Machine (SVM)	Klassifikation, Regression, Bildklassifikation	Robust, Kernel-Methode ermöglicht nichtlineare Trennung	Hoher Rechenaufwand bei großen Datensätzen, schwer interpretierbar	Accuracy, Precision, Recall, ROC-AUC	[vgl. Noble 2006, S.1565-1567; Mammon et al. 2009, S.283-286; Mehta und N. Agrawal 2018, S.297; Navia-Vázquez und Parrado-Hernández 2006, S.1755]
Naive Bayes	Textklassifikation, Spam-Filter	Schnell, benötigt wenig Daten	Unabhängigkeitsannahme oft nicht erfüllt	Accuracy, Precision, Recall, F1-Score	[vgl. S.-B. Kim et al. 2006, S.1457-1458; K. P. Murphy et al. 2006, S.4-5; C. Li et al. 2014, S.256; Rish, Irina 2001, S.46; Vujovic 2021, S.3-4; Salmi und Rustam 2019, S.6]
K-Nearest Neighbors	Klassifikation, Regression	Einfach, keine Trainingsphase	Hoher Speicherbedarf, langsam bei großen Datensätzen	Accuracy, MSE, F1-Score, ROC-AUC	[vgl. Batista, D. F. Silva et al. 2009, S.1-2; Z. Zhang 2016, S.4-6; Mucherino et al. 2009, S.83-84; Nguyen und Guo 2008, S.125-126; Laaksonen und Oja 1996, S.1480-1482; M. Pagan et al. 2023, S.135-136]
Convolutional Neural Networks (CNN)	Bildklassifikation, Objekterkennung	Automatisches Feature-Learning, hohe Genauigkeit bei Bilddaten	Hohe Rechenkosten, große Datenmengen erforderlich	Accuracy, Top-K-Accuracy, IoU	[vgl. O'Shea und Nash 2015, S.2-3; J. Wu 2017, S.2-3; Z. Li et al. 2022, S.6999-7000; Gu et al. 2018, S.355-358; Krichen 2023, S.27-28; Dogan 2023, S.578; Yan et al. 2019, S.1-3]

Tabelle 18: Überblick über ausgewählte Supervised Learning Modelle

Methode	Anwendungsgebiet	Vorteile	Nachteile	Mögliche Metriken	Quelle
Recurrent Networks (RNN, LSTM, GRU)	Neural Zeitreihenprognosen, NLP, Spracherkennung	Modelliert sequenzielle Abhängigkeiten	Lange Trainingszeiten Probleme mit langen Abhängigkeiten	Accuracy, BLEU, MSE	[vgl. Salehinejad et al. 2018, S.1-2; R. M. Schmidt 2019, S.1-2; Graves 2013, S.1-3; Levin 1990, S.642; Williams et al. 2015, S.5391; Sundermeyer et al. 2014, S.14-15; Connor et al. 1994, S.240-241; Graves 2016, S.1-2]

Tabelle 19: Beispiele für Modellparameter ausgewählter Verfahren

Methoden	Beispiele Standard-Modellparameter	Beispiele Hyperparameter
Entscheidungsbäume	• Eingabevariable, die an einem inneren Knoten herangezogen wird • Schwellwert, der an diesem inneren Knoten zur Aufspaltung bestimmt wird	• Minimale Anzahl an Dateninstanzen pro Blattknoten • Strategie zum Pruning (Kürzen) des Baumes nach Abschluss des Trainings
Random Forest	• Eingabevariable, die an einem inneren Knoten herangezogen wird • Schwellwert, der an diesem inneren Knoten zur Aufspaltung bestimmt wird	• Anzahl der Entscheidungsbäume im Modell • Anzahl der Eingabevariablen pro Knoten
Support Vector Machine (SVM)	• Stützvektoren des Modells • Lagrange-Multiplikatoren, die jedem Stützvektor zugeordnet sind	• Verwendeter Kerntyp (z. B. linear, polynomial, radial) • Grad des Polynomial-Kernels • Regularisierungskonstante C • Rundungsfehlertoleranz ε • Toleranzparameter für die Optimierung
Naive Bayes	• Bedingte Wahrscheinlichkeit $p(x_i c)$ für eine Eingabevariable x_i bei Klasse c • Prior-Wahrscheinlichkeit $p(c)$ für das Auftreten jeder Klasse	• Wahl der Dichtefunktion (z. B. Normalverteilung, Kernel-Schätzung) • Fensterbreite (Bandbreite) des Kernel-Dichteschätzers
K-Nearest Neighbors	• —	• Anzahl der berücksichtigten Nachbarn (k) • Gewichtungsmechanismus der Nachbarn • Verwendete Distanzfunktion
Neuronale Netze	• Gewichtungen der Verbindungen zwischen den Neuronen	• Anzahl der versteckten Schichten (Hidden Layers) • Anzahl der Knoten pro Schicht • Anzahl der Trainings-Epochen • Lernrate des Backpropagation-Algorithmus

B Suchalgorithmus

1. („production“ OR „production machine“ OR „process integration“) AND („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“) AND („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („technical documentation“ OR „digital twin“) AND („database“ OR „it architecture“ OR „data pipeline“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
2. („production“ OR „production machine“ OR „process integration“) AND („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“)
3. („production“ OR „production machine“ OR „process integration“) AND („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“)
4. („production“ OR „production machine“ OR „process integration“) AND („technical documentation“ OR „digital twin“)
5. („production“ OR „production machine“ OR „process integration“) AND („database“ OR „it architecture“ OR „data pipeline“)
6. („production“ OR „production machine“ OR „process integration“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
7. („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“) AND („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“)
8. („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“) AND („technical documentation“ OR „digital twin“)
9. („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“) AND („database“ OR „it architecture“ OR „data pipeline“)
10. („industrial internet of things“ OR „digital transformation“ OR „smart factory“ OR „smart maintenance“ OR „industry 4.0“ OR „smart sensors“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
11. („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („technical documentation“ OR „digital twin“)
12. („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („database“ OR „it architecture“ OR „data pipeline“)
13. („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
14. („technical documentation“ OR „digital twin“) AND („database“ OR „it architecture“ OR „data pipeline“)

15. („technical documentation“ OR „digital twin“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
16. („database“ OR „it architecture“ OR „data pipeline“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
17. („production“) AND („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („technical documentation“ OR „digital twin“) AND („database“ OR „it architecture“ OR „data pipeline“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
18. („production“) AND („maintenance strategies“ OR „condition monitoring“ OR „predictive maintenance“ OR „prescriptive maintenance“ OR „knowledge based maintenance“) AND („data mining“ OR „data preprocessing“ OR „machine learning“ OR „deep learning“ OR „text mining“)
19. („production“) AND („maintenance strategies“) AND („technical documentation“) AND („data mining“)
20. („production“) AND („maintenance strategies“) AND („data mining“)
21. („technical documentation“) AND („data mining“ OR „text mining“)

C Konzeptmatrix der relevanten Autoren

Tabelle 20: Übersicht der Autoren und ihrer Beiträge

Nr.	Autoren (Jahr)	P	TT	IH	AD	IT	DS
1	<i>Ahmad und Kamaruddin (2012)</i>	x	-	x	-	-	-
2	<i>Van Horenbeek et al. (2014)</i>	x	-	x	-	-	-
3	<i>Ferreiro et al. (2016)</i>	x	x	x	x	-	x
4	<i>Uhlemann et al. (2017)</i>	x	x	-	x	x	-
5	<i>Gurjanov et al. (2018)</i>	-	x	-	-	x	-
6	<i>Hurban und Szendiuch (2018)</i>	-	x	-	-	x	-
7	<i>Schneider et al. (2019)</i>	x	x	x	-	x	-
8	<i>Antonino et al. (2019)</i>	-	x	x	-	x	-
9	<i>Zakoldaev et al. (2019)</i>	-	x	-	-	x	-
10	<i>Bellavista et al. (2019)</i>	x	x	-	-	x	x
11	<i>Pavlu et al. (2019)</i>	x	x	x	-	x	-
12	<i>Zhai et al. (2019)</i>	x	-	x	-	-	x
13	<i>Badwelan et al. (2019)</i>	x	x	x	-	-	x
14	<i>Mohamed et al. (2019)</i>	x	x	x	-	x	x
15	<i>Poor et al. (2019)</i>	x	x	x	-	-	x
16	<i>Lee et al. (2020)</i>	x	x	x	x	x	x
17	<i>Sang et al. (2020)</i>	x	x	x	x	x	x
18	<i>Kammerer et al. (2020)</i>	x	x	-	-	x	x
19	<i>Massaro et al. (2020)</i>	x	x	x	-	x	x
20	<i>Wei et al. (2020)</i>	-	x	-	-	x	-
21	<i>Knoblauch et al. (2021)</i>	x	x	-	-	x	-
22	<i>Paolanti et al. (2018)</i>	x	x	x	-	x	x
23	<i>Spendla et al. (2017)</i>	x	x	x	-	x	x
24	<i>Compare (2020)</i>	x	x	x	-	x	x
25	<i>Krupitzer et al. (2020)</i>	x	x	x	-	-	x
26	<i>Cinar et al. (2020)</i>	x	-	x	-	-	x
27	<i>Sang et al. (2021)</i>	x	x	x	-	x	x
28	<i>Löcklin et al. (2021)</i>	x	x	-	x	x	-
29	<i>Morselli et al. (2021)</i>	x	x	x	-	x	x
30	<i>Zenkert et al. (2021)</i>	-	x	x	-	x	-
31	<i>Ren et al. (2021)</i>	x	x	x	x	x	x
32	<i>Pech et al. (2021)</i>	x	x	x	-	-	x
33	<i>Chen et al. (2008)</i>	-	-	-	-	-	x
34	<i>Pretty und Blackwell (2009)</i>	-	-	-	-	-	x
35	<i>Jablonski et al. (2013)</i>	-	-	x	-	-	x
36	<i>Kesavaraj und Sukumaran (2013)</i>	-	-	-	-	-	x

Tabelle 20: Übersicht der Autoren und ihrer Beiträge

Nr.	Autoren (Jahr)	P	TT	IH	AD	IT	DS
37	<i>Kateris et al. (2014)</i>	x	-	x	-	-	x
38	<i>Feng et al. (2013)</i>	-	-	x	-	-	x
39	<i>Vidulin et al. (2014)</i>	-	-	-	-	-	x
40	<i>Denkena et al. (2014)</i>	x	x	-	-	-	x
41	<i>Günther et al. (2014)</i>	x	-	-	-	-	x
42	<i>Wollschläger et al. (2015)</i>	x	-	x	-	x	-
43	<i>Somvanshi et al. (2016)</i>	-	-	-	-	-	x
44	<i>Han und Chi (2016)</i>	x	x	x	-	-	x
45	<i>Lazakis et al. (2016)</i>	-	-	x	-	x	-
46	<i>Maksood und Achuthan (2016)</i>	-	x	-	-	x	x
47	<i>Glawar et al. (2016)</i>	x	-	x	-	-	x
48	<i>Kanawaday und Sane (2017)</i>	x	x	x	-	x	x
49	<i>Bertoni et al. (2017)</i>	-	x	-	-	x	x
50	<i>Singh und Sharma (2017)</i>	-	-	-	-	x	x
51	<i>Mehdiyev et al. (2017)</i>	x	-	-	-	x	x
52	<i>Fatima und Pasha (2017)</i>	-	-	-	-	-	x
53	<i>Baylor et al. (2017)</i>	-	-	-	-	x	x
54	<i>Schmidt und Wang (2016)</i>	x	x	x	x	x	x
55	<i>Zekveld und Hancke (2018)</i>	x	x	x	-	x	x
56	<i>Aremu et al. (2018)</i>	x	-	x	x	x	x
57	<i>Butte et al. (2018)</i>	x	-	x	-	-	x
58	<i>Shi et al. (2019)</i>	x	-	x	-	-	x
59	<i>Wang et al. (2020)</i>	-	-	x	x	-	x
60	<i>Sossenheimer et al. (2019)</i>	x	-	-	-	-	x
61	<i>Nemeth et al. (2018)</i>	x	-	x	-	x	x
62	<i>Glawar et al. (2019)</i>	x	-	x	-	x	-
63	<i>Ansari et al. (2019)</i>	x	-	x	x	x	x
64	<i>Nemeth et al. (2019)</i>	x	-	x	-	-	-
65	<i>Ahmad et al. (2018)</i>	x	x	x	-	-	x
66	<i>Schenkelberg et al. (2020)</i>	x	-	x	x	x	x
67	<i>Oleghe und Saloniitis (2020)</i>	x	-	-	-	x	-
68	<i>Shaheen und Németh (2022)</i>	x	x	x	-	x	x
69	<i>Zhong et al. (2023)</i>	x	x	x	x	x	x
70	<i>Mao et al. (2023)</i>	x	x	x	-	x	x
71	<i>Wesendrup et al. (2024)</i>	x	-	x	-	x	x
72	<i>Krishna Menon und Tuladhar (2024)</i>	x	x	x	-	-	x
73	<i>Klein et al. (2025)</i>	x	-	x	x	-	x
74	<i>Mallioris et al. (2024)</i>	x	x	x	-	-	x

Tabelle 20: Übersicht der Autoren und ihrer Beiträge

Nr.	Autoren (Jahr)	P	TT	IH	AD	IT	DS
75	<i>Giacotto et al. (2025)</i>	x	-	x	-	-	-
76	<i>de Souza und Rocha (2024)</i>	x	-	x	-	-	-
77	<i>Wahab et al. (2024)</i>	x	x	x	-	-	x
78	<i>Van Dinter et al. (2023)</i>	x	x	x	-	x	x
79	<i>Bellavista und Mora (2019)</i>	x	x	-	-	x	-
80	<i>Choubey et al. (2020)</i>	x	-	x	-	x	-
81	<i>Anton et al. (2020)</i>	x	x	x	-	x	-
82	<i>Kohl et al. (2021)</i>	x	-	x	x	x	x
83	<i>Uhlmann et al. (2021)</i>	x	-	x	-	x	x
84	<i>Süve et al. (2022)</i>	x	x	x	-	x	x
85	<i>Fortoul-Diaz et al. (2023)</i>	x	x	-	x	x	-
86	<i>dos Santos et al. (2023)</i>	x	x	x	-	x	-
87	<i>Giacotto et al. (2024)</i>	x	-	x	-	x	-
88	<i>Weller et al. (2024)</i>	x	x	x	-	x	-
89	<i>Abdullahi et al. (2024)</i>	-	x	x	-	x	x
90	<i>Ordieres-Meré et al. (2025)</i>	x	-	x	-	x	x
91	<i>Chen et al. (2025)</i>	x	x	x	-	x	x
92	<i>Mallioris et al. (2025)</i>	x	-	x	x	-	x
93	<i>Parapalli und Shetty (2025)</i>	x	-	x	-	-	x

Tabelle 21: Konzeptmatrix der relevanten Autoren

IH-Strategie				AD		IT		DS														
Nr.	CM	PM	KBM	TAD	DLA	DZ	I	DB	K	DV	SM	S	US	DMK	DMG	ML	DL	VE	APD	ARD	SD	AVD
21	-	x	-	-	-	-	x	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-
22	-	x	-	x	-	-	x	x	x	x	-	x	-	x	-	x	-	-	-	x	-	-
23	-	x	-	x	-	-	x	x	x	x	-	-	-	x	-	x	-	-	x	-	-	-
24	-	x	-	x	-	-	x	-	-	x	x	x	-	-	x	x	-	-	-	-	-	-
25	x	x	-	-	-	-	-	-	-	x	x	-	-	-	-	x	-	-	-	-	-	-
26	-	x	-	-	-	-	x	-	-	x	x	x	x	-	-	x	x	-	-	-	-	-
27	-	x	-	x	-	-	x	x	x	x	-	x	-	x	-	x	-	x	-	x	-	x
28	-	-	-	-	-	x	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-
29	-	x	-	-	-	-	x	-	x	x	-	-	x	x	-	x	-	-	-	x	-	-
30	-	x	x	x	-	-	x	x	x	x	-	x	x	-	-	x	x	-	-	-	-	x
31	-	-	x	x	-	-	x	-	-	x	-	x	-	x	-	-	x	-	x	-	-	x
32	-	x	-	-	-	-	x	-	-	x	-	-	-	-	-	x	-	-	-	-	-	x
33	-	-	-	-	-	-	-	-	-	x	-	x	x	-	x	-	-	-	x	-	-	-
34	-	-	-	-	-	-	-	-	-	x	-	-	x	x	-	x	-	x	x	-	-	-
35	x	-	-	-	-	-	-	-	-	x	x	-	-	x	-	-	-	-	-	x	-	-
36	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	x	-	x	-	-	-	-
37	x	-	-	-	-	-	-	-	-	x	-	-	x	x	-	x	-	x	x	-	-	-
38	x	-	-	-	-	-	-	-	-	x	-	-	x	x	-	x	-	x	-	-	x	-
39	-	-	-	-	-	-	-	-	-	x	x	x	-	x	-	x	-	x	-	-	x	-
40	-	-	x	-	-	-	-	x	x	x	x	x	-	x	-	x	-	-	x	-	-	x

Tabelle 21: Konzeptmatrix der relevanten Autoren

IH-Strategie				AD		IT		DS														
Nr.	CM	PM	KBM	TAD	DLA	DZ	I	DB	K	DV	SM	S	US	DMK	DMG	ML	DL	VE	APD	ARD	SD	AVD
41	-	-	-	-	-	-	X	-	-	X	-	-	X	X	-	-	X	X	X	-	-	-
42	X	-	-	-	-	-	X	-	X	-	-	-	-	-	-	-	-	-	-	-	-	-
43	-	-	-	-	-	-	-	-	-	X	-	X	-	-	-	X	-	-	-	-	-	-
44	X	X	-	-	-	-	-	-	-	X	-	X	-	X	-	X	-	X	X	-	-	X
45	X	-	-	-	-	-	X	X	-	-	-	-	-	-	-	-	-	-	-	X	-	-
46	-	-	-	-	-	-	X	X	-	-	-	X	X	-	X	-	-	-	-	X	-	-
47	X	X	-	-	-	-	X	-	-	X	-	-	-	-	X	-	-	X	-	-	X	-
48	X	X	X	-	-	-	X	X	X	X	-	X	-	X	-	X	-	X	X	-	-	-
49	-	-	-	-	-	-	X	-	-	X	-	X	X	X	-	X	-	X	-	-	-	-
50	-	-	-	-	-	-	X	-	-	X	-	-	X	-	X	-	X	-	-	X	-	-
51	-	-	-	-	-	-	X	-	-	X	-	-	X	-	X	-	X	-	X	-	-	-
52	-	-	-	-	-	-	-	-	-	-	-	X	X	X	X	X	X	-	-	X	-	-
53	-	-	-	-	-	-	X	X	-	X	X	X	X	-	X	X	X	X	-	X	-	-
54	X	X	X	-	-	-	X	X	X	-	X	-	-	-	X	-	-	X	X	-	-	X
55	X	X	-	-	-	-	X	-	X	X	-	X	X	X	-	X	X	X	X	-	-	-
56	X	X	X	X	-	-	X	-	-	X	-	-	-	-	-	X	X	X	-	-	-	-
57	-	X	-	-	-	-	X	-	-	X	-	X	X	X	-	X	X	-	X	-	-	-
58	X	X	-	-	-	-	-	-	-	X	X	X	X	-	X	X	X	X	X	-	-	-
59	X	X	-	X	-	-	X	-	-	X	-	X	-	-	X	X	-	X	-	X	-	-
60	X	X	-	-	-	-	-	-	-	-	X	-	X	-	X	X	-	X	-	-	X	X

Tabelle 21: Konzeptmatrix der relevanten Autoren

IH-Strategie				AD		IT		DS														
Nr.	CM	PM	KBM	TAD	DLA	DZ	I	DB	K	DV	SM	S	US	DMK	DMG	ML	DL	VE	APD	ARD	SD	AVD
61	-	-	x	-	-	-	x	x	-	-	-	-	-	-	-	x	x	-	-	-	-	x
62	-	-	x	x	-	-	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-
63	x	x	x	x	-	-	x	x	-	x	x	x	x	x	-	x	x	x	x	-	-	x
64	-	x	x	-	-	-	x	-	-	-	x	-	-	x	-	-	-	-	x	-	-	-
65	x	x	-	-	-	-	x	-	-	x	x	-	-	x	-	-	-	x	x	-	-	-
66	-	-	x	-	-	-	x	-	-	x	-	x	-	x	-	x	-	-	x	-	-	x
67	x	x	-	x	-	-	x	x	x	x	-	-	-	x	-	x	-	-	-	x	-	-
68	x	x	x	-	-	-	-	-	-	-	-	-	-	-	-	x	x	-	-	-	-	-
69	-	x	-	-	-	x	-	-	-	x	x	x	x	-	-	x	x	x	x	-	-	x
70	x	x	x	-	-	x	x	-	-	x	x	-	x	-	x	x	x	x	x	-	-	x
71	-	-	x	-	-	-	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
72	-	x	-	-	-	-	-	-	-	x	x	-	-	-	-	x	x	-	-	-	-	-
73	-	x	x	-	-	-	-	-	-	x	x	x	x	x	-	x	x	x	x	-	-	-
74	-	x	x	-	-	-	-	-	-	-	x	-	-	-	-	x	x	-	-	-	-	-
75	-	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
76	x	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
77	-	x	-	-	-	x	-	-	-	-	-	-	-	-	-	x	x	-	-	-	-	-
78	-	x	-	-	-	x	x	x	x	-	-	-	-	-	-	-	-	-	-	-	x	-
79	-	x	-	-	-	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
80	-	-	x	x	-	-	x	x	-	-	-	-	-	-	x	-	-	x	-	x	-	x

Tabelle 21: Konzeptmatrix der relevanten Autoren

IH-Strategie				AD		IT		DS														
Nr.	CM	PM	KBM	TAD	DLA	DZ	I	DB	K	DV	SM	S	US	DMK	DMG	ML	DL	VE	APD	ARD	SD	AVD
81	-	x	-	-	-	x	x	-	-	-	x	-	-	-	x	-	x	-	-	-	-	-
82	-	-	x	x	-	-	x	-	-	x	x	-	-	-	-	x	-	x	x	-	-	-
83	x	x	-	-	-	-	x	x	x	-	-	-	x	x	-	-	x	-	-	-	x	-
84	-	x	-	-	-	x	x	x	-	x	-	-	x	-	x	-	x	-	-	x	-	x
85	-	-	-	-	-	-	x	x	x	-	-	x	-	-	x	x	x	-	-	-	x	-
86	x	x	x	-	-	x	x	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
87	-	-	x	-	-	-	x	-	-	-	-	-	-	-	x	-	-	-	-	x	-	x
88	-	-	x	-	-	-	x	-	-	-	-	-	-	-	-	-	-	-	x	-	-	x
89	-	x	-	-	-	x	x	x	x	x	-	-	x	x	-	x	-	x	-	-	-	-
90	-	-	x	-	-	-	x	-	-	-	-	-	x	-	x	x	x	x	x	-	-	-
91	x	x	x	-	-	x	x	-	-	-	x	x	x	-	-	x	x	-	-	-	-	-
92	-	x	x	x	-	-	x	-	-	x	-	x	-	-	-	x	x	x	x	-	-	-
93	-	x	-	-	-	-	x	-	-	-	-	-	x	-	x	x	-	x	x	-	-	-

D Im Rahmen der Forschung entstandene Arbeiten

Tabelle 22: Im Rahmen der Forschung entstandenen Arbeiten

Nr.	Veröffentlichte Arbeiten
1	[Klees und Evirgen 2022, vgl.]
2	[Steenbuck et al. 2023, vgl.]
3	[Dobbert und Evirgen 2023, vgl.]
4	[Evirgen und Wartenberg 2024, vgl.]

E Kommunikationskette intelligenten Data Pipeline

Strasse	Status	Info
HWN_VIB01	1	X-Tools Model Started
HWN_VIB02	1	X-Tools Model Started
SWN_OPCUA_CM-SPS	1	X-Tools Model Started
SWN_SPS-Fast	1	X-Tools Model Started
SWN_SPS-Slow	1	X-Tools Model Started
SWN_Simotion_Stufe_1	1	X-Tools Model Started
SWN_Simotion_Stufe_2	1	X-Tools Model Started
SWN_Simotion_Stufe_3	1	X-Tools Model Started
SWN_Simotion_Stufe_4	1	X-Tools Model Started
SWN_Simotion_Stufe_5	1	X-Tools Model Started
SWN_Simotion_Stufe_6	1	X-Tools Model Started
SWN_Simotion_Stufe_7	1	X-Tools Model Started
SWN_Simotion_Ziehkissen	1	X-Tools Model Started

Abbildung 58: Kommunikationsaufbau X-Tools

jo	Enabled	Topic Name	Unit	Assigned Data	Source Type	Destination Type	Size	Data Model	Publishing Interval [ms]	Compressed
21	☒	Pressenposition	*	Pressenposition	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
22	☒	Stoßelposition	mm	Stoßelposition	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
23	☒	Verdraenger_Istdruck1	bar	Verdränger_Istdruck [1]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
24	☒	Verdraenger_Istdruck2	bar	Verdränger_Istdruck [2]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
25	☒	Verdraenger_Istdruck3	bar	Verdränger_Istdruck [3]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
26	☒	Verdraenger_Istdruck4	bar	Verdränger_Istdruck [4]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
27	☒	Verdraenger_Istdruck5	bar	Verdränger_Istdruck [5]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
28	☒	Verdraenger_Istdruck6	bar	Verdränger_Istdruck [6]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
29	☒	Verdraenger_Istdruck7	bar	Verdränger_Istdruck [7]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
30	☒	Verdraenger_Istdruck8	bar	Verdränger_Istdruck [8]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
31	☒	Verdraenger_Solldruck1	bar	Verdränger_Solldruck [1]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
32	☒	Verdraenger_Solldruck2	bar	Verdränger_Solldruck [2]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
33	☒	Verdraenger_Solldruck3	bar	Verdränger_Solldruck [3]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
34	☒	Verdraenger_Solldruck4	bar	Verdränger_Solldruck [4]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
35	☒	Verdraenger_Solldruck5	bar	Verdränger_Solldruck [5]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
36	☒	Verdraenger_Solldruck6	bar	Verdränger_Solldruck [6]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
37	☒	Verdraenger_Solldruck7	bar	Verdränger_Solldruck [7]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
38	☒	Verdraenger_Solldruck8	bar	Verdränger_Solldruck [8]	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
39	☒	Werkzeugnummer	1	Werkzeugnummer	Decimal32	Decimal32	N/A	Timestamps + Values, JSON	Default (1000)	☐
40				Drag&drop the data which shall be output from the MDS Explorer						

Abbildung 59: Topics für die Fallstudie Ziehkissen

```
{
  "topic": "XTools_DATA/Verdraenger_Istdruck5",
  "message": [
    {
      "t": "2021-07-06T11:07:03.000000000Z",
      "v": 18.7
    },
    {
      "t": "2021-07-06T11:07:03.001000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.001000000Z",
      "v": 18.7
    },
    {
      "t": "2021-07-06T11:07:03.003000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.004000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.004000000Z",
      "v": 18.6
    },
    {
      "t": "2021-07-06T11:07:03.006000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.007000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.008000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.010000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.012000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.013000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.014000000Z",
      "v": 18.6
    },
    {
      "t": "2021-07-06T11:07:03.015000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.016000000Z",
      "v": 18.5
    },
    {
      "t": "2021-07-06T11:07:03.017000000Z",
      "v": 18.3999
    },
    {
      "t": "2021-07-06T11:07:03.018000000Z",
      "v": 18.3
    },
    {
      "t": "2021-07-06T11:07:03.019000000Z",
      "v": 18.3
    },
    {
      "t": "2021-07-06T11:07:03.020000000Z",
      "v": 18.3
    },
    {
      "t": "2021-07-06T11:07:03.021000000Z",
      "v": 18.2
    },
    {
      "t": "2021-07-06T11:07:03.022000000Z",
      "v": 18.3
    },
    {
      "t": "2021-07-06T11:07:03.023000000Z",
      "v": 18.3
    }
  ]
}
```

Abbildung 60: Beispiel publizierte Datennachricht Ziehkissen




Abbildung 61: Applikationen Industrial Edge Management System

```
{
  "id": "label",
  "timestamp": "2021-09-02T12:31:00.000Z",
  "value": "0"
}
```

```
{
  "id": "label",
  "timestamp": "2021-09-18T12:16:00.000Z",
  "value": "1"
}
```

Abbildung 62: Ausgabepaket des Ziehkissen-Modells

F Fallstudie Druckluftgreifer




Abbildung 63: Vergleich: 3 σ - und IQR-Ausreißeranalyse für alle Luftverbrauchssensoren




Abbildung 64: Mittlerer Luftverbrauch je Sensor über Pressenposition

G Interviewleitfaden für die Experteninterviews

Tabelle 23: Interviewleitfaden für die semistrukturierten Experteninterviews

Interviewteil	Zielsetzung	Beispielhafte Leitfragen
Teil A	Einordnung des Gesprächskontexts und Verortung der Domänenexpertise	• Können Sie bitte kurz Ihren beruflichen Hintergrund und Ihren aktuellen Tätigkeitsbereich beschreiben? • In welchen fachlichen Domänen würden Sie Ihre Expertise verorten? • Haben Sie Berührungspunkte mit datengetriebenen Ansätzen in der Produktion, der Instandhaltung oder im Kontext von Data Pipelines?
Teil B – Nützlichkeit	Bewertung des praktischen Mehrwerts und der Problem-Lösungs-Passung	• Wie nützlich erscheint Ihnen das präsentierte Referenzmodell der intelligenten Data Pipeline? • Welche realen Problemstellungen im Produktionsumfeld werden aus Ihrer Sicht adressiert? • Wie bewerten Sie den praktischen Nutzen der dargestellten Anwendungsfälle?
Teil B – Verständlichkeit	Bewertung der strukturellen und inhaltlichen Nachvollziehbarkeit	• Ist der Aufbau und die Struktur des Referenzmodells nachvollziehbar? • Sind die dargestellten Anwendungsfälle und deren Ergebnisse verständlich? • Gibt es Aspekte, die aus Ihrer Sicht unklar oder unnötig komplex sind?
Teil B – Anwendbarkeit	Einschätzung der Umsetzbarkeit unter realen industriellen Rahmenbedingungen	• Halten Sie die Umsetzung des Referenzmodells im industriellen Umfeld für realistisch? • Welche technischen oder organisatorischen Voraussetzungen sind aus Ihrer Sicht notwendig? • Inwieweit halten Sie das Referenzmodell für reproduzierbar unter vergleichbaren Rahmenbedingungen?

Interviewteil	Zielsetzung	Beispielhafte Leitfragen
Teil B – Übertragbarkeit	Bewertung der Skalierbarkeit und Übertragbarkeit	• Wie schätzen Sie die grundsätzliche Übertragbarkeit des Referenzmodells ein? • Lassen sich die Erkenntnisse auf andere Produktionskontexte übertragen? • Welche Anpassungen wären hierfür erforderlich?
Teil B – Akzeptanz	Einordnung soziotechnischer Aspekte und Nutzerperspektiven	• Wie schätzen Sie die Akzeptanz des Referenzmodells im operativen Umfeld ein? • Welche Faktoren fördern oder behindern die Einführung datengetriebener Ansätze? • Welche Rolle spielt Vertrauen in datenbasierte Analyseergebnisse?
Teil C	Erfassung weiterführender Praxiserfahrungen und Einschätzungen	• Welche Erfahrungen haben Sie mit datengetriebenen Projekten gemacht? • Wie schätzen Sie den Stellenwert prädiktiver und weiterführender datengetriebener Instandhaltungsansätze ein? • Welche Herausforderungen ergeben sich bei der Nutzung von Analyseergebnissen im operativen Betrieb?
Teil D	Abschließende offene Reflexion und Ergänzungen	• Gibt es Aspekte des Referenzmodells, die kritisch zu hinterfragen oder weiter zu präzisieren wären? • Haben Sie ergänzende Anmerkungen zu den dargestellten Anwendungsfällen? • Gibt es weitere relevante Aspekte, die bislang nicht angesprochen wurden?