Aktivitäts- und kontextsensitive Prozesserkennung in der Intralogistik

Zur Erlangung des akademischen Grades eines
Dr.-Ing.
von der Fakultät Maschinenbau
der Technischen Universität Dortmund

genehmigte Dissertation

Friedrich Niemann, M.Sc.
aus
Ostseebad Kühlungsborn, Deutschland

Tag der mündlichen Prüfung: 15. Oktober 2026

Erste Gutachterin: Prof. Dr.-Ing. Alice Kirchheim
Zweiter Gutachter: Prof. Dr.-Ing. Stefan Lüdtke

Dortmund, 2026

Vorwort und Danksagung

Die vorliegende Dissertation entstand im Rahmen meiner Tätigkeit am Lehrstuhl für Förder- und Lagerwesen an der Fakultät Maschinenbau der Technischen Universität Dortmund. Sie basiert auf einem gemeinsamen Drittmittelprojekt mit dem Institute for Visual and Analytic Computing, der Fakultät für Informatik und Elektrotechnik der Universität Rostock sowie den Unternehmen MotionMiners GmbH und SimulationsDienstleistungsZentrum GmbH. Wesentliche Grundlagen wurden zuvor in Forschungsprojekten in Zusammenarbeit mit der Pattern Recognition in Embedded Systems Group der Fakultät Informatik der Technischen Universität Dortmund erarbeitet.

Mein besonderer Dank gilt zunächst meiner Erstgutachterin Prof. Dr.-Ing. Alice Kirchheim für ihre fachliche Unterstützung und die gewährten wissenschaftlichen Freiräume. Ebenso danke ich Prof. Dr. Dr. h. c. Michael ten Hompel für seine Förderung. Meinem Zweitgutachter Prof. Dr.-Ing. Stefan Lüdtke danke ich für die konstruktiven Anregungen und das fachliche Feedback, das diese Arbeit wesentlich bereichert hat.

Moh'd Khier Al Kfari, Nilah Ravi Nair, Christopher Reining und Fernando Moya Rueda danke ich herzlich für die langjährige Zusammenarbeit, die zahlreichen fachlichen Diskussionen und ihre wertvollen Impulse, aus denen schließlich das Thema dieser Arbeit hervorging.

Allen an der Erstellung der Datensätze beteiligten Personen danke ich für ihre Unterstützung. Ohne den Einsatz der Helferinnen und Helfer bei Vorbereitung und Durchführung der Datenerhebung sowie der Probanden, Annotatoren und Revisoren wäre diese Arbeit nicht möglich gewesen. Insbesondere danke ich Hashem Almatalka, Hussam Asskar, Eileen Bork, Fabian König, Syed Abdul Haseeb Qadri, Mohammad Youssef und Kai Zurkuhl für ihre umfangreiche und sorgfältige Annotation und Revision, Michael Frichert für die Videobearbeitung, Markus Heinzelmann für die Unterstützung bei der Erstellung von Abbildungen, Sebastian Beierle für die Fotodokumentation sowie Laura Dziuba für ihre Begleitung während der Abfassung der Arbeit. Mein Dank gilt ebenso allen weiteren wissenschaftlichen Hilfskräften, Mitarbeitenden und Studierenden, die zum Gelingen beigetragen haben.

Für die institutionelle Unterstützung danke ich den Projektpartnern MotionMiners GmbH, der SimulationsDienstleistungsZentrum GmbH und dem Institute for Visual and Analytic Computing. Ebenso danke ich Veronika Kretschmer und Linda Maria Wings für die Bereitstellung des Forschungslabors am Fraunhofer-Institut für Materialfluss und Logistik IML.

Abschließend danke ich meiner Familie und meinen Freunden für ihre Unterstützung während der gesamten Promotionszeit. Besonders danke ich meiner Frau Janine Niemann und meinem Sohn Karl Niemann. Ihre liebevolle Güte, Geduld und ihr Zuspruch schenkten mir stets die nötige Motivation, diese Arbeit mit voller Hingabe zu schreiben.

Dortmund, im Juni 2026 *Friedrich Niemann*

Kurzfassung

Diese Arbeit präsentiert ein Verfahren zur automatischen Erkennung von Arbeitsprozessen auf Basis menschlicher Aktivitäts- und Kontextinformationen. Bisherige Ansätze der menschlichen Aktivitätserkennung sind als automatisches Verfahren zur Ermittlung von Ist-Zeitdaten in der Intralogistik nach dem Vorbild der REFA-Zeitstudie unzureichend. Ihre Klassifikationsergebnisse sind bislang kaum semantisch interpretierbar und erlauben keine Ableitung von Arbeitsprozessen.

Auf Grundlage systematischer Literatur- und Datensatzanalysen wurde ein Framework zur standardisierten Erstellung annotierter Aktivitätsdatensätze entwickelt und mittels einer quantitativen Umfrage unter Autoren bestehender Benchmark-Datensätze sowie durch eine konzeptionelle Analyse der Generalisierbarkeit auf verwandte Forschungsbereiche und industrielle Unternehmen evaluiert.

Auf dem Framework aufbauend wurde ein multimodaler, manuell annotierter Datensatz für intralogistische Arbeitsprozesse (DaRA) erstellt. Im Gegensatz zu bestehenden Datensätzen enthält er neben Bewegungsaktivitäten auch kontextuelle Annotationen und eine deutlich höhere Labelgranularität. Dadurch lassen sich erkannte Aktivitäten konkreten Arbeitsschritten zuordnen und auf mehreren Abstraktionsebenen vom einzelnen Handlungsschritt bis zum Gesamtprozess analysieren.

Auf Basis dieses Datensatzes wurden Verfahren zur Prozesserkennung mittels überwachten Deep Learnings empirisch evaluiert. Die Experimente zeigen, dass sich Prozessschritte bereits aus reduzierten Aktivitäts- und Ortsinformationen rekonstruieren lassen. Teilprozesse werden mit einem F1-Maß von 78,65 % und Feinprozesse von 58,67 % erkannt.

Die Ergebnisse zeigen, dass menschliche Aktivitätserkennung über die Analyse von Bewegungsmustern hinaus als Instrument zur strukturierten Analyse intralogistischer Arbeitsprozesse eingesetzt werden kann. Dies eröffnet die Möglichkeit einer automatisierten Auswertung von Arbeitsabläufen.

Abstract

This thesis presents a method for the automatic recognition of work processes based on human activity and contextual data. Existing approaches to detecting human activity are inadequate as an automated method for determining actual time data in intralogistics, based on the REFA time study method. Their classification results have so far been largely impossible to interpret semantically and do not allow for the identification of work processes.

Based on systematic literature and dataset analyses, a framework for the standardized creation of annotated activity datasets was developed and evaluated through a quantitative survey of authors of existing benchmark datasets and a conceptual analysis of generalizability to related research areas and industrial enterprises.

Building on the framework, a multimodal, manually annotated dataset for intralogistics work processes (DaRA) was created. In contrast to existing datasets, it contains contextual annotations and a significantly higher label granularity in addition to movement activities. This allows recognized activities to be assigned to specific work steps and analyzed at several levels of abstraction, from individual action steps to the overall process.

Based on this dataset, methods for process recognition using supervised deep learning were empirically evaluated. The experiments indicate that process steps can already be reconstructed from reduced activity and location information. Sub-level processes are recognized with an F1 score of 78.65 % and low-level processes with 58.67 %.

The results prove that human activity recognition can be used as a tool for structured analysis of intralogistical work processes beyond the analysis of movement patterns. This opens up the possibility of automated evaluation of workflows.

Inhaltsverzeichnis

Abbildungsverzeichnis xiii

Tabellenverzeichnis xv

Abkürzungs- und Akronymverzeichnis xvii

1 Einleitung 1

2 Grundlagen 7
2.1 Intralogistik 8
2.1.1 Stellenwert der Intralogistik und des Menschen 8
2.1.2 Informationsfluss-, Materialfluss- und Organisationssystem 9
2.1.3 Grundprinzipien und Leistungsberechnung 11
2.1.4 Informationstechnische Führung 13
2.1.5 Systemtypen in der Kommissionierung 14
2.1.6 Wegstrategien bei eindimensionaler Fortbewegung 15
2.2 Zeitwirtschaft 17
2.2.1 Bedeutung der Zeitwirtschaft 18
2.2.2 Zeitwirtschaftliche Methoden 19
2.2.3 Manuelle Methoden der Ist-Zeitdatenmessung 20
2.2.4 Menschliche Aktivitätserkennung als automatisierte Methode der Ist-Zeitdatenmessung 23
2.2.5 Soll-Zeitdatenbestimmung mit MTM 26

3 Limitationen bestehender Forschungsarbeiten auf dem Gebiet der menschlichen Aktivitätserkennung 29
3.1 HAR als Methode der Ist-Zeitdatenermittlung 30
3.2 Kontextinformationen im Rahmen der HAR 31
3.3 Systematische Übersicht von HAR-Datensätzen 33
3.3.1 HAR-Datensätze ohne Arbeitsbezug 35
3.3.2 HAR-Datensätze mit Arbeitsbezug 40

3.4 Methoden der Datensatzerstellung für HAR 43

4 Methodik 45
4.1 Explorative Studie | CAARL 46
4.1.1 Erstellung des CAARL-Datensatzes 46
4.1.2 Methodik der kontextsensitiven Aktivitätserkennung . 49
4.1.3 Evaluation der kontextsensitiven Aktivitätserkennung 51
4.1.4 Schlussfolgerungen für die Prozesserkennung 53
4.2 Entwicklung eines Prozesserkennungsverfahrens 54
4.3 Framework zur Datensatzerstellung 56
4.3.1 Phase 1 | Planung der Datensatzerstellung 57
4.3.2 Phase 2 | Vorbereitung der Datenaufnahme 62
4.3.3 Phase 3 | Durchführung der Datenaufnahme 64
4.3.4 Phase 4 | Vorbereitung der Datenverarbeitung 65
4.3.5 Phase 5 | Durchführung der Datenverarbeitung 70
4.3.6 Phase 6 | Veröffentlichung des Datensatzes 73
4.3.7 Checkliste 74

5 Empirischer Beitrag zur aktivitäts- und kontextsensitiven Prozesserkennung 77
5.1 Erstellung des DaRA-Datensatzes 78
5.1.1 Phase 1 | Planung der Datensatzerstellung 78
5.1.2 Phase 2 | Vorbereitung der Datenaufnahme 89
5.1.3 Phase 3 | Durchführung der Datenaufnahme 94
5.1.4 Phase 4 | Vorbereitung der Datenverarbeitung 96
5.1.5 Phase 5 | Durchführung der Datenverarbeitung 102
5.1.6 Phase 6 | Veröffentlichung des Datensatzes 108
5.2 Empirische Fundierung der Prozesserkennung 109
5.2.1 Beschreibung der Prozessebenen und ihrer Labels 109
5.2.2 Klassenkategorische Hierarchie der Prozesserkennung 110
5.2.3 Korrelation zwischen Aktivitäten, Kontext und Prozessen 112

6 Evaluationen 115
6.1 Evaluation der Methode zur Datensatzerstellung 116
6.1.1 Umfrage zur Checkliste 116
6.1.2 Anwendbarkeit der Checkliste in verwandten Forschungsbereichen 120
6.1.3 Anwendbarkeit der Checkliste in Unternehmen 120
6.2 Empirische Evaluation des DaRA-Datensatzes 120
6.2.1 Labelqualität 121
6.2.2 Analysiergeschwindigkeit 122
6.2.3 Sensordatenqualität 124

6.2.4 Qualität von Label-Sensor-Kombinationen 125
6.3 Empirische Evaluation der Prozesserkennung 127

7 Fazit und Ausblick 131
7.1 Datensatzerstellung | Framework und Checkliste 131
7.2 Datensatz | DaRA 132
7.3 Prozesserkennung | aktivitäts- und kontextsensitiv 133

Literaturverzeichnis 135

Anhang 165
A.1 Weitere Tabellen und Abbildungen zum DaRA-Datensatz 165
A.1.1 BPMN-Modellierungen von Teilprozessen 165
A.1.2 Taxonomien des DaRA-Datensatzes 168
A.1.3 Artikelstammdaten des Picking Labs 172
A.1.4 Visuelle Dokumentation von Artikeln 173
A.1.5 Kundenaufträge 177
A.1.6 Zeitlicher Ablauf der Szenarien je Proband 180
A.1.7 Explorative Anwendungen des DaRA-Datensatzes 181
A.2 Vorveröffentlichungen 183
A.3 Forschungsprojekte 185
A.4 Ethikvotum und Probandeneinwilligung 186
A.5 An den Forschungsarbeiten beteiligte Personen 192
A.6 Erklärung zur Verwendung generativer KI-Systeme 194
A.7 Studentische Arbeiten im Rahmen der Forschungsarbeiten . . . 195

Abbildungsverzeichnis

1.1 Inhaltliche Struktur der Forschungsarbeit 5

2.1 Konventionelles Kommissionieren 15
2.2 Wegstrategien bei eindimensionaler Fortbewegung 16
2.3 Anwendungsbereiche der Zeitwirtschaft 18
2.4 Zusammenhang von Ist-, Soll-, Plan- und Vorgabezeiten 21
2.5 Soll-Zeitdatenbestimmung nach dem Leistungsgradprinzip 23
2.6 Exemplarische Verarbeitungskette der Aktivitätserkennung 25
2.7 MTM-Bausteinsysteme im Überblick 27

3.1 Methode der Datensatzrecherche 34
3.2 Anzahl von HAR-Datensätzen nach Erscheinungsjahr 34

4.1 Logo des CAARL-Datensatzes 46
4.2 Exemplarische Darstellung der Logistikszenarien 47
4.3 oMoCap-Rekonstruktion des Versuchsaufbaus 47
4.4 Zuordnung von oMoCap-Markern zum Verpackungsszenario 48
4.5 Exemplarische Annotationssequenz 50
4.6 Architektur der kontextsensitiven Aktivitätserkennung 51
4.7 Modulare Datenverarbeitungskette für die Prozesserkennung 56
4.8 Framework zur Datensatzerstellung 57
4.9 Interpretation des Kappa-Koeffizienten 73

5.1 Logo des DaRA-Datensatzes 78
5.2 Picking Lab des Fraunhofer IML 79
5.3 Grundriss des Picking Labs: bemaßt 80
5.4 Informationstechnische Führung für die Kommissionierung 82
5.5 Sensoren zur Bewegungserfassung 85
5.6 Synchronisierte Kameraperspektiven 86
5.7 Grundriss des Picking Labs: Sensorpositionen 87
5.8 Probandenübersicht des DaRA-Datensatzes 89
5.9 Grundriss des Picking Labs: Zonierung des Versuchsaufbaus 92

5.10 Panoramablick auf den Versuchsaufbau 93
5.11 Idealisiertes BPMN der Grobprozesse 95
5.12 Exemplarische DaRA-Annotation im Annotationstool SARA 101
5.13 Exemplarische Sequenz annotierter Labels des DaRA-Datensatzes 105
5.14 Sankey-Diagramm der Prozessebenen 110
5.15 Klassenkategorische Hierarchie der Prozesserkennung 111
5.16 Korrelation zwischen Aktivitäten und Prozessen 113

6.1 Interpretation der Labelqualität 122
6.2 Vergleich der Feinprozesserkennungsleistung 129
6.3 Vergleich der Teilprozesserkennungsleistung 130

A.1 BPMN des Teilprozesses *Auftrag vorbereiten* 165
A.2 BPMN der Teilprozesse *Kommissionierung* (*Wegzeit* und *Greifzeit*) . . 165
A.3 BPMN des Teilprozesses *Auspacken* 166
A.4 BPMN des Teilprozesses *Verpacken* 166
A.5 BPMN der Teilprozesse *Einlagerung* (*Wegzeit* und *Greifzeit*) 166
A.6 BPMN des Teilprozesses *Auftrag abschließen* 167
A.7 Artikel aus dem Regalkomplex 1, Gasse 1 173
A.8 Artikel aus dem Regalkomplex 2, Gasse 2 174
A.9 Artikel aus dem Regalkomplex 3, Gasse 2 174
A.10 Artikel aus dem Regalkomplex 4, Gasse 3 175
A.11 Artikel aus dem Regalkomplex 5, Gasse 3 175
A.12 Artikel aus dem Regalkomplex 6, Gasse 4 176
A.13 Artikel aus dem Regalkomplex 7, Gasse 4 176
A.14 Artikel aus dem Regalkomplex 8, Gasse 5 176
A.15 Simulationslauf auf Basis des DaRA-Datensatzes 181
A.16 Extraktion menschlicher Skelette auf Basis des DaRA-Datensatzes 182

Tabellenverzeichnis

2.1 Taxonomie des Informationsflusssystems nach Grundfunktionen . 10
2.2 Taxonomie des Materialflusssystems nach Grundfunktionen 11
2.3 Taxonomie des Organisationssystems nach Teilsystemen 12
2.4 Führung kommissionierender Personen 14
2.5 Methodenüberblick der Zeitdatenermittlung 20
2.6 Gliederung des Multimomentverfahrens 21
2.7 Grundbewegungen bei MTM-1 28

3.1 Systematische Übersicht von HAR-Datensätzen ohne Arbeitsbezug 37
3.2 Systematische Übersicht von HAR-Datensätzen mit Arbeitsbezug 41

4.1 Annotationsergebnisse nach Klassenlabels unterteilt 49
4.2 Makro-F1-Maß der Klassifikatoren 52
4.3 Klassenweises F1-Maß des RF-Modells 52
4.4 Ergebnisse der Greedy-Feature-Auswahl (QDA, Distanzmerkmale) 53
4.5 Ergebnisse der Greedy-Feature-Auswahl (RF, Distanzmerkmale) . 53
4.6 Ergebnisse der Greedy-Feature-Auswahl (RF, Rohdaten) 53
4.7 Taxonomie der Datensatzerstellung: HAR-Anwendungsbereiche . 58
4.8 Taxonomie der Datensatzerstellung: Aufnahmeumgebungen 58
4.9 Taxonomie der Datensatzerstellung: Szenarien 59
4.10 Taxonomie der Datensatzerstellung: Sensortypen 61
4.11 Taxonomie der Datensatzerstellung: Probandencharakteristiken .. 63
4.12 Kontextlabelkategorien 65
4.13 Bewegungslabelkategorien mit Beispiellabeln 66
4.14 Taxonomie der Datensatzerstellung: Labelstruktur 67
4.15 Taxonomie der Datensatzerstellung: Annotationsmethoden 69
4.16 Funktionsübersicht von verfügbaren Annotationstools 69
4.17 Taxonomie der Datensatzerstellung: Revisionsmethoden 71
4.18 Checkliste für die Datensatzerstellung 74

5.1 Spezifikation der acht Szenarien 84

5.2 Probandencharakteristiken im Überblick 90
5.3 Klassenkategorien und Klassenlabels 96
5.4 Probandenzuweisung zu den Aufnahmesessions 103
5.5 Annotation- und Revisionsaufwand je Klassenkategorie 108

6.1 Umfrageergebnisse zur Checkliste 117
6.2 Labelqualität des DaRA-Datensatzes 121
6.3 Vergleich der Analysiergeschwindigkeiten von MTM und HAR . . 123
6.4 Klassifikationsleistung der Aktivitätserkennung je Klasse 125
6.5 Klassifikationsleistung der Aktivitätserkennung: Konfusionsmatrix 126
6.6 Gesamte Klassifikationsleistung der Aktivitätserkennung 126
6.7 Übersicht der Experimente zur Prozesserkennung 127
6.8 Gesamte Klassifikationsleistung der Prozesserkennung 128

A.1 Einordnung von DaRA in die Taxonomie von HAR-Datensätzen . 168
A.2 Einordnung von DaRA im Informationssystem 170
A.3 Einordnung von DaRA im Materialflusssystem 170
A.4 Einordnung von DaRA im Organisationssystem 171
A.5 Artikelstammdaten 172
A.6 Kundenauftrag *2904* 177
A.7 Kundenauftrag *2905* 177
A.8 Kundenauftrag *2906* 178
A.9 Kundenauftrag *2904+2905* 179
A.10 Szenarienreihenfolge für jeden Probanden 180
A.11 Start- und End-Frames der Szenarien 180
A.12 Dokumentvorlage der Probandeninformation und -einwilligungserklärung 186
A.13 An dem CAARL-Datensatz beteiligte Personen und ihre Beiträge . 192
A.14 An dem DaRA-Datensatz beteiligte Personen und ihre Beiträge . . . 192
A.15 KI-Systeme im Rahmen der Arbeit 194
A.16 Studentische Arbeiten im Rahmen der Forschungsarbeiten 195

Abkürzungs- und Akronymverzeichnis

AAL	Ambient Assisted Living
ADL	Activities of Daily Living
BLE	Bluetooth Low Energy
BPMN	Business Process Model and Notation
CAARL	Context-Aware Activity Recognition in Logistics
CNN	Convolutional Neural Network
DaRA	Data Fusion for advanced Research in industrial Applications
DOI	Digital Object Identifier
fps	frames per second
FPV	First-Person View
GPS	Global Positioning System
HAR	Human Activity Recognition
HCR	Human Context Recognition
HMM	Hidden Markov Model
IML	Institut für Materialfluss und Logistik
IMU	Inertial Measurement Unit
k-NN	k-Nearest Neighbor
KI	Künstliche Intelligenz
KK	Klassenkategorie
KL	Klassenlabel
LARa	Logistic Activity Recognition Challenge
LOG	Logistik

LSTM	Long Short-Term Memory
MDE	Mobile Datenerfassung
MEK	Mehrzweck-Einzel- und Kleinserienfertigung
MTM	Methods-Time Measurement
oMoCap	optisches Motion Capture
PbL	Pick-by-Light
PbV	Pick-by-Voice
PtL	Put-to-Light
PzW	Person-zur-Ware
QDA	Quadratic Discriminant Analysis
REFA	Reichsausschuss für Arbeitszeitermittlung
RF	Random Forest
RNN	Recurrent Neural Network
RSSI	Received Signal Strength Indicator
SARA	Sequence Attribute Retrieval Annotator
SD	Standarddaten
SVM	Support Vector Machine
SvZ	Systeme vorbestimmter Zeiten
TCNN	Temporal Convolutional Neural Network
TPV	Third-Person View
UAS	Universelles Analysiersystem
WMS	Warehouse Management System
WzP	Ware-zur-Person
XGBoost	eXtreme Gradient Boosting

Kapitel 1
Einleitung

Motivation

Trotz der zunehmenden Verfügbarkeit sensorbasierter Erfassungssysteme und leistungsfähiger Verfahren des maschinellen Lernens werden Zeitdaten manueller Arbeit in der Intralogistik nach wie vor überwiegend mit klassischen Methoden der Zeitwirtschaft erhoben. Diese basieren typischerweise auf direkten Beobachtungen durch geschulte Mitarbeiter und der manuellen Erfassung von Arbeitsabläufen, etwa im Rahmen von REFA-Zeitstudien des Verbands für Arbeitsgestaltung, Betriebsorganisation und Unternehmensentwicklung e. V., ehemals Reichsausschuss für Arbeitszeitermittlung (REFA) [REF97]. Derartige Verfahren sind jedoch aufwendig, kostenintensiv, nur begrenzt skalierbar und unterliegen zudem subjektiven Einflüssen [LDL16, S. 199]; [Sad07, S. 84].

Gleichzeitig kommt Zeitdaten eine zentrale Bedeutung für die betriebliche Praxis zu. Insbesondere in der Intralogistik, die weiterhin durch einen hohen Anteil manueller Tätigkeiten geprägt ist, bestimmen Personalkosten maßgeblich die Kostenstruktur von Unternehmen [Kuh+23]. Vor dem Hintergrund steigender Lohnkosten gewinnen Effizienzgrößen wie Durchlaufzeiten, Arbeitsproduktivität und Ressourcenauslastung zunehmend an Bedeutung [Jun+18, S. 11]. Eine fundierte Bewertung und Optimierung entsprechender Arbeitssysteme setzt jedoch die Verfügbarkeit belastbarer und differenzierter Zeitdaten voraus [Olb93, S. 19].

In der Praxis wird auf deren systematische Erhebung häufig verzichtet und stattdessen auf Erfahrungswerte oder vereinfachte Schätzungen zurückgegriffen [Gud10, S. 869]; [AMW10; WS14]. Dies führt zu einer unzureichenden Datengrundlage für Planung, Steuerung und kontinuierliche Verbesserung logistischer Prozesse.

Vor diesem Hintergrund rücken automatisierte Ansätze zur Erfassung menschlicher Arbeit zunehmend in den Fokus. Durch den Einsatz von Wearables und Umgebungssensoren lassen sich Bewegungsdaten kontinuierlich und mit vergleichsweise geringem Aufwand erfassen [Men+20]. Verfahren

der Human Activity Recognition (HAR) ermöglichen darauf aufbauend die automatische Klassifikation menschlicher Aktivitäten mittels maschinellen Lernens und werden bereits in verschiedenen industriellen Kontexten eingesetzt [Fel18; Rei+18a; Rei+18b].

Diese Ansätze adressieren jedoch primär die Erkennung isolierter Aktivitäten. Für betriebliche Anwendungen ist deren Bedeutung jedoch erst durch die Einordnung in einen übergeordneten Arbeitszusammenhang erschließbar. Ohne eine solche Kontextualisierung bleibt die Aussagekraft erkannter Aktivitäten begrenzt, wodurch ein Bedarf an Verfahren zur kontextsensitiven Interpretation sensorischer Daten entsteht [Che+13b; LNH14; RF18]. Dies wird durch eine quantitative Umfrage unter 397 Unternehmen aus dem Logistikbereich gestützt, die zwar das Potenzial von HAR bestätigt, gleichzeitig jedoch die Notwendigkeit kontextsensitiver Modelle hervorhebt [Sta+26].

Problemstellung

Verfahren der HAR ermöglichen die zuverlässige Klassifikation einzelner Aktivitäten auf Basis sensorischer Daten. Für betriebliche Entscheidungs- und Analysefragen in der Intralogistik ist jedoch nicht die isolierte Aktivität von Interesse, sondern der zugrunde liegende Arbeitsprozess, in den diese eingebettet ist [Olb93, S. 19]. Erst durch die prozessuale Einordnung lassen sich belastbare Aussagen über den bearbeiteten Auftrag, die korrekte Durchführung von Arbeitsvorgängen sowie deren zeitliche Struktur ableiten.

Selbst bei hoher Erkennungsgenauigkeit einzelner Aktivitäten bleibt die betriebliche Interpretierbarkeit daher eingeschränkt [Che+13b; LNH14; RF18]. Einzelne Aktivitätsklassen erlauben keine eindeutigen Rückschlüsse auf vollständige Prozessabläufe, da identische Aktivitäten in unterschiedlichen Kontexten auftreten und ihre Bedeutung erst aus der Abfolge sowie aus prozessualen Kontextinformationen hervorgeht.

Für die weitere Argumentation ist ein präzises Verständnis des zugrunde liegenden Prozessbegriffs erforderlich:

Definition: *Prozess*

Ein menschenzentrierter Prozess beschreibt eine indeterminierte Abfolge zusammenhängender oder einander beeinflussender menschlicher Handlungen und Entscheidungen, die auf das Erreichen eines Ergebnisses ausgerichtet sind (angelehnt an [Dav93; ISO9000; Sen+21; Wes07]).

Für eine fundierte Analyse und Optimierung manueller Arbeitssysteme ist es daher erforderlich, erkannte Aktivitäten zu konsistenten, semantisch interpretierbaren Prozessen zu aggregieren. Dies erfordert insbesondere:

- die Modellierung von Zusammenhängen zwischen Aktivitäten,
- die Berücksichtigung zeitlicher und logischer Abfolgen,
- sowie die Integration zusätzlicher Kontextinformationen.

Ein Verfahren, das diese Anforderungen erfüllt und die ganzheitliche Erkennung intralogistischer Prozesse auf Basis sensorisch erfasster Aktivitätsdaten ermöglicht, ist bislang nicht verfügbar. Bestehende Forschungsarbeiten fokussieren überwiegend die Klassifikation einzelner Aktivitäten, ohne deren systematische Überführung in prozessuale Strukturen zu adressieren [Che+13b; LNH14; RF18].

Vor diesem Hintergrund ergibt sich die zentrale Herausforderung, ein Verfahren zu entwickeln, das über die reine Aktivitätserkennung hinausgeht und eine kontextsensitive Interpretation sensorischer Daten im Sinne vollständiger intralogistischer Arbeitsprozesse ermöglicht. Dabei sind insbesondere folgende Herausforderungen zu adressieren:

- **Klassenlabels:** Die Prozesserkennung erfordert die Definition geeigneter Klassenlabels, die sowohl Aktivitäts- als auch Kontextinformationen umfassen. Die hohe Vielfalt potenziell relevanter Informationen erschwert die Auswahl geeigneter und eindeutig abgrenzbarer Klassen.
- **Sensorik:** Die Erfassung prozessrelevanter Kontextinformationen erfordert eine geeignete Kombination von Bewegungs- und Umgebungssensorik, deren Auswahl und Integration anwendungsspezifische Anforderungen berücksichtigt.
- **Variabilität von Layouts und Prozessen:** Intralogistische Systeme weisen eine hohe Variabilität in Bezug auf Lagerlayouts sowie Prozessausprägungen auf, wodurch eine Generalisierbarkeit von Erkennungsansätzen erschwert wird.
- **Granularität von Prozessen:** Prozesse bestehen aus hierarchisch strukturierten Aktivitäten und Kontextinformationen unterschiedlicher Granularität, was die Definition geeigneter Abstraktionsebenen für die Modellierung und Erkennung erschwert.
- **Datenverfügbarkeit:** Die Erstellung geeigneter Datensätze ist mit hohem Aufwand verbunden, insbesondere hinsichtlich Datenerhebung, Annotation und Sicherstellung der Datenqualität.
- **Klassifikatoren:** Die Eignung von Machine-Learning-Modellen für die intralogistische Prozesserkennung ist bislang nicht untersucht.

Forschungslücken und abgeleitete Forschungsfragen

Forschungslücke 1: Aktuelle HAR-Ansätze konzentrieren sich überwiegend auf die Klassifikation von Aktivitäten auf Basis einzelner Bewegungen. Der arbeitsorganisatorische Zusammenhang wird dabei jedoch nur unzureichend

berücksichtigt [Rei21, S. 148]. In der Konsequenz manifestiert sich eine Diskrepanz zwischen der technisch realisierbaren Aktivitätserkennung und der für betriebliche Anwendungen erforderlichen Prozessinterpretation. Ohne diese semantische Kontextualisierung sind die ableitbaren Aussagen zur Bewertung und Optimierung intralogistischer Prozesse nur eingeschränkt belastbar.

Forschungsfrage 1: *Prozesserkennung*

Wie lassen sich aus mittels HAR erkannten Einzelaktivitäten übergeordnete intralogistische Arbeitsprozesse automatisch erkennen?

Forschungslücke 2: Die Entwicklung und Evaluation von Verfahren der Prozesserkennung setzen geeignete Daten voraus. Es fehlen jedoch frei verfügbare, realitätsnahe Benchmark-Datensätze, die Bewegungen, Kontextinformationen und Prozessstrukturen intralogistischer Arbeitsabläufe gemeinsam abbilden. Vorhandene Datensätze basieren häufig auf künstlichen Szenarien oder sind unzureichend dokumentiert, wodurch ihre Nachnutzbarkeit sowie die Vergleichbarkeit darauf basierender Verfahren eingeschränkt ist [Ala+23; Rei+19a].

Forschungsfrage 2: *Datensatz*

Welche Eigenschaften charakterisieren einen HAR-Datensatz zur validen Abbildung menschlicher Aktivitäten und intralogistischer Arbeitsprozesse?

Forschungslücke 3: Die eingeschränkte Datenverfügbarkeit ist unter anderem auf das Fehlen standardisierter Vorgehensmodelle zur Datensatzerstellung zurückzuführen. Dies erschwert sowohl die Erstellung neuer Datensätze als auch die Überprüfbarkeit wissenschaftlicher Ergebnisse. In der Künstliche Intelligenz (KI)-Forschung wird dieses Problem als Teil einer Reproduzierbarkeits- bzw. Datensatzkrise diskutiert [Hut18; Zha+22]. Obwohl für Datensätze im maschinellen Lernen bereits übergeordnete Empfehlungen existieren [Hut+21; SHD21], fehlen bislang spezifische Richtlinien für HAR-Datensätze, insbesondere hinsichtlich der Planung der Datensatzerstellung sowie der Datenaufnahme und -verarbeitung. Der Fokus der HAR-Forschung liegt primär auf der Modellentwicklung, also auf den Schritten nach der Datensatzerstellung, während die Datenerhebung, Datenqualität und insbesondere die Übertragbarkeit auf reale Anwendungsszenarien bislang kaum adressiert werden.

Forschungsfrage 3: *Datensatzerstellung*

Welche Schritte definieren ein standardisiertes Framework zur Erstellung von HAR-Datensätzen zur Sicherstellung von Reproduzierbarkeit, Vergleichbarkeit und Qualität?

Zielstellung und methodischer Ansatz

Ziel dieser Arbeit ist die automatische Erkennung intralogistischer Arbeitsprozesse auf Grundlage sensorisch erfasster menschlicher Bewegungen [Dou04; Ick+22; SBG99]. Die Ableitung von Prozesszuständen aus klassifizierten Aktivitäten und ermittelten Lokalisierungsangaben erweitert die Aktivitätserkennung um eine semantische Ebene und ermöglicht dadurch eine systematische Analyse manueller Arbeitsabläufe [Dey01]. Damit wird eine datenbasierte Auswertung materialflussbezogener Arbeitssysteme angestrebt, die funktional an arbeitswissenschaftliche Untersuchungen in Anlehnung an die REFA-Zeitstudie anknüpft, jedoch ohne manuelle Beobachtung auskommt.

Ausgehend von den identifizierten Forschungslücken verfolgt die Arbeit ein dreistufiges Vorgehen (siehe Abbildung 1.1). Zunächst wird auf Basis von systematischen Literatur- und Datensatzrecherchen ein **Framework inklusive Checkliste** zur Erstellung von HAR-Datensätzen entwickelt. Aufbauend auf den Modellannahmen aus einer explorativen Studie zur kontextsensitiven Aktivitätserkennung sowie des Frameworks zur Datensatzerstellung wird ein domänenspezifischer **Datensatz** mit Aktivitäts-, Kontext- und Prozessannotationen erhoben. Dieser Datensatz dient anschließend als Grundlage für die Entwicklung und Evaluation des ersten Verfahrens zur automatischen aktivitäts- und kontextsensitiven **Prozesserkennung** in der Intralogistik.

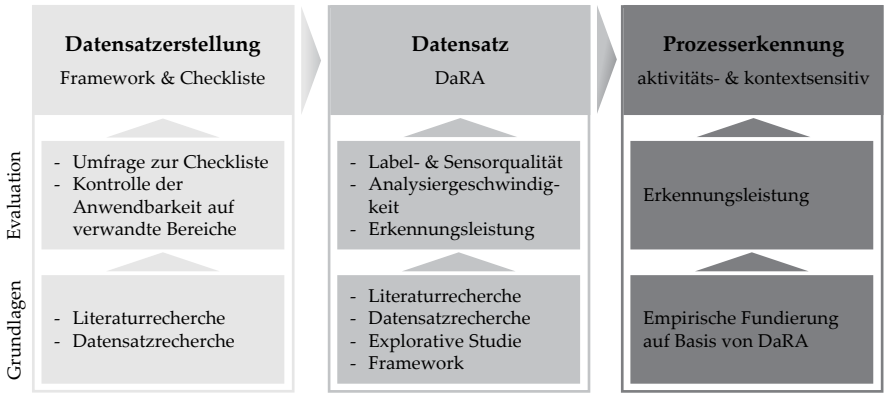


Abb. 1.1 Inhaltliche Struktur der Forschungsarbeit

Kapitel 2
Grundlagen

Zusammenfassung Im zweiten Kapitel werden die fachlichen Grundlagen erläutert, indem zentrale Strukturen intralogistischer Arbeitsabläufe am Beispiel der manuellen Kommissionierung dargestellt und beschrieben werden. Kommissionierprozesse bestehen aus wiederkehrenden und klar strukturierten Handlungsschritten, deren Bewertung neben den ausgeführten Bewegungen auch Kontextinformationen zum Arbeitsablauf erfordert. Die Zeitwirtschaft wird als etabliertes Instrument zur Analyse solcher Arbeitsprozesse betrachtet. Manuelle Verfahren der Ist-Zeitdatenmessung ermöglichen eine anpassungsfähige, auf den Anwendungsfall individualisierte Prozessbewertung, sind jedoch mit erheblichem Erfassungsaufwand verbunden. Ansätze der menschlichen Aktivitätserkennung ermöglichen eine automatisierte Datenerfassung, liefern bislang jedoch überwiegend bewegungsbasierte Informationen ohne Einordnung in tatsächliche Arbeitsprozesse. Damit wird die Bedeutung einer automatisierten Erfassung und zugleich inhaltlich interpretierbaren Analyse intralogistischer Arbeitsprozesse begründet.

Dieses Kapitel basiert teilweise auf den folgenden Veröffentlichungen:

Christopher Reining und Friedrich Niemann. *Kommissionierung - Systeme, Strategien und Technologien für effiziente Materialflusssysteme*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-70190-4

Christopher Reining und Friedrich Niemann. *Order Picking - Systems, Strategies, and Technologies for Efficient Material Flow Systems*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-73391-2

Christopher Reining u. a. „Human Activity Recognition for Production and Logistics—A Systematic Literature Review“. In: *Information* (2019). DOI: 10.3390/info10080245

Katja Ickstadt u. a. „Lernverfahren der Künstlichen Intelligenz zur Inwertsetzung von Daten: Automatisierte Erkennung und Prognose“. In: *Silicon Economy*. Hrsg. von Michael ten Hompel, Michael Henke und Boris Otto. Berlin, Heidelberg: Springer Berlin Heidelberg, 2022. DOI: 10.1007/978-3-662-63956-6_11

2.1 Intralogistik

In den folgenden Abschnitten werden die für den Hauptteil dieser Arbeit relevanten Begriffe der Intralogistik definiert und voneinander abgegrenzt. Aufgrund der zentralen Rolle des Menschen im Lagerwesen liegt der Schwerpunkt der Grundlagenbetrachtung auf der manuellen Kommissionierung.

2.1.1 Stellenwert der Intralogistik und des Menschen

Die Relevanz der Intralogistik lässt sich aus ihrem Anteil an den Unternehmenskosten, ihrer wirtschaftlichen Wertschöpfung sowie aus Beschäftigungskennzahlen ableiten. Die folgenden Statistiken unterscheiden sich zwar aufgrund abweichender Unterteilung logistischer Sektoren, weisen jedoch übereinstimmend auf dieselben Trends hin.

Kostenanteil und Wertschöpfung

In Deutschland verursacht die Logistik bis zu 15 % des Gesamtumsatzes eines Unternehmens und stellt damit einen zentralen Hebel für Optimierungsmaßnahmen dar [PS09]. Bei detaillierter Betrachtung entfallen bis zu 70 % der Logistikkosten auf Lagerung und Distribution; hiervon wiederum bis zu 70 % auf die Kommissionierung [DLR07; PS09]. Daraus ergibt sich, dass die Kommissionierung im Durchschnitt rund 5 % des Unternehmensumsatzes ausmacht. Vergleichbare Kostenstrukturen lassen sich auch in anderen Ländern, etwa in Finnland, beobachten [Sol+15; Sol+23]. Die konkreten Werte variieren abhängig von Branche und Unternehmensstruktur [Fra02; SP08].

Die Branche *Lagerei* erzielte in Deutschland im Jahr 2021 einen Umsatz von 14,7 Mrd. €. Davon entfielen 80,8 % auf den Sektor *Lagerei und lagereiverwandte Dienstleistungen*, 13,7 % auf *Güterbeförderung im Straßenverkehr* und 5,5 % auf den *Frachtumschlag* [Sta21]. Berücksichtigt werden dabei ausschließlich Unternehmen mit wirtschaftlichem Schwerpunkt im Lagerwesen; Lageraktivitäten innerhalb von Produktionsbetrieben sind nicht Bestandteil dieser Statistik.

Auf europäischer Ebene verzeichnete der Sektor *Transportation and storage* im Jahr 2022 eine Gesamtwertschöpfung von 642,7 Mrd. €. Nach dem Subsektor *Land transport and transport via pipelines* stellte *Warehousing and support activities for transportation* mit 29,6 % den zweitgrößten Anteil an der Wertschöpfung. [Eur22a]

Beschäftigungskennzahlen

Trotz zunehmender Automatisierung – insbesondere im innerbetrieblichen Transport – bleibt der Mensch im Lager ein zentraler Faktor. Grund dafür sind seine der aktuellen Robotik weiterhin überlegenen Wahrnehmungs-, Entscheidungs- und Greiffähigkeiten, insbesondere bei ungeordnet bereitgestellten und häufig wechselnden Artikelsortimenten. Dies und der wach-

sende E-Commerce [Eur22b] spiegeln sich in der Entwicklung der Beschäftigtenzahlen wider. Nach Angaben der Bundesvereinigung Logistik (BVL) stieg die Zahl der Logistikbeschäftigten in Deutschland von 3,05 Millionen im Jahr 2016 auf 3,30 Millionen im Jahr 2021, was einer Zunahme von 8,2 % entspricht [BVL26].

Das Statistische Bundesamt weist im Wirtschaftsbereich *Verkehr und Lagerei* zwischen 2008 (1,99 Millionen Beschäftigte) und 2023 (2,41 Millionen Beschäftigte) einen Beschäftigungsanstieg von 20,7 % aus [Sta25].

EU-weit waren im Jahr 2022 im Sektor *Transportation and Storage* 10,38 Millionen Personen beschäftigt, davon 22,06 % (2,29 Millionen) in Deutschland. Im Subsektor *Warehousing and support activities for transportation* arbeiteten europaweit 24,09 % bzw. rund 2,5 Millionen Beschäftigte. Ein Beschäftigter dieses Subsektors generiert dabei überproportional hohe Wertschöpfung: etwa das 1,7-Fache eines Beschäftigten im größeren Subsektor *Land transport and transport via pipelines* sowie etwa das Doppelte gegenüber *Postal and courier activities*. Entsprechend weist der Subsektor mit 12,42 % die höchste Brutto-Operationsrate auf. Die durchschnittlichen jährlichen Aufwendungen für Mitarbeiterleistungen betragen in Deutschland 42,6 Tsd. € und liegen damit 9,7 % über dem europäischen Mittelwert. [Eur22a]

2.1.2 Informationsfluss-, Materialfluss- und Organisationssystem

Nach der [VDI3590-1] lässt sich die Kommissionierung in die Systeme Informationfluss, Materialfluss und Organisation gliedern.

Informationsflusssystem

Das Informationsflusssystem erfasst und verarbeitet die für Auslösung und Durchführung der Kommissionierung erforderlichen Informationen und stellt sie der kommissionierenden Person bereit. Zentrale Elemente sind der Kunden- und der Kommissionierauftrag sowie die darin enthaltenen Positionen [VDI3590-1]. Diese bilden sich in den vier Grundfunktionen des Informationsflusssystems ab (siehe Tabelle 2.1).

Die ersten drei Grundfunktionen betreffen die Vorbereitung der Kommissionierung [RN26a; VDI3590-1]. Zunächst wird der Kundenauftrag aufgenommen und anschließend in einen Kommissionierauftrag überführt. Entspricht der Kundenauftrag unmittelbar dem Kommissionierauftrag, liegt ein Einzelauftrag (*Single Order Picking*) vor. Bearbeitet eine Person mehrere Kundenaufträge gleichzeitig, werden diese zu einer Auftragsgruppe zusammengefasst, die – je nach Kundenerkennung – als *Multi Order Picking* (mit Kundenerkennung) oder *Batch* (ohne Kundenerkennung) bezeichnet wird [RN26a]. Bei der Verteilung eines Kundenauftrags auf mehrere Kommissio-

Tabelle 2.1 Taxonomie des Informationsflusssystems nach Grundfunktionen [RN26a; VDI3590-1]

Grundfunktion	Realisierungsmöglichkeiten			
Auftragserfassung	manuell	manuell, automatisch	automatisch	
Auftragsaufarbeitung	Einzelauftrag	Auftragsgruppen	Teilauftrag	
	keine	manuell	manuell, automatisch	automatisch
Weitergabe	ohne Beleg	mit Beleg		
	Einzelposition	mehrere Positionen		
Quittierung	je Entnahmeeinheit	je Position	alle Positionen	
	manuell	manuell, automatisch	automatisch	

nieraufträge, handelt es sich um Teilaufträge [RN26a]. Anschließend wird der Kommissionierauftrag in eine oder mehrere Pickpositionen übergeben.

Die Quittierung bezeichnet die Bestätigung eines logistischen Arbeitsschritts, bei der der Systemzustand erfasst und der Bestand fortgeschrieben wird. Ihre konkrete Ausgestaltung hängt von der eingesetzten informationstechnischen Führung ab [RN26a; VDI3590-1].

Materialflusssystem

Die physische Handhabung der Artikel wird im Materialflusssystem abgebildet. Der in Tabelle 2.2 zusammengefasste Transport umfasst die Zuführung der Artikel zur Bereitstellung, die Bewegung der kommissionierenden Person zum Bereitstellort, den Transport der Artikel zum Abgabeort sowie den Rücktransport angebrochener Ladeeinheiten [VDI3590-1]; [HSD18, S. 275 ff.]. Die Transporte erfolgen eindimensional (z. B. Fachbodenregal), zweidimensional (z. B. Hochregalkommissionierung) oder dreidimensional (z. B. mittels Kran). Nur in wenigen Sonderfällen, etwa bei Schachtkommissionierern, findet während der Kommissionierung keine unmittelbare Bewegung von Mensch oder Roboter statt [RN26a].

Bereitstellung und Abgabe der Artikel weisen identische Realisierungsformen auf [HSD18, S. 275 ff.]. Die Entnahme von einer oder mehreren Einheiten eines Artikels, auch Stückgut bezeichnet, erfolgt entweder manuell, mit mechanischer Unterstützung oder vollautomatisch [VDI3590-1].

Tabelle 2.2 Taxonomie des Materialflusssystems nach Grundfunktionen [RN26a; VDI3590-1]

Grundfunktion	Realisierungsmöglichkeiten			
Transport	keine Bewegung	Bewegung		
		manuell	mechanisiert	automatisiert
		1-dimensional	2-dimensional	3-dimensional
Bereitstellung/ Abgabe	statisch	dynamisch		
	zentral	dezentral		
	geordnet	teilgeordnet	ungeordnet	
Entnahme	manuell	mechanisiert	automatisiert	
	Einzelstückgut	Sammelstückgut		

Organisationssystem

Das Organisationssystem gliedert sich in die drei Teilsysteme *Aufbau-*, *Ablauf-* und *Betriebsorganisation* (siehe Tabelle 2.3). Die Aufbauorganisation beschreibt die strukturelle Zonierung der Lagerbereiche und manifestiert sich in der technischen Umsetzung sowie den Artikeleigenschaften. Die, durch Durchlaufzeit, Zugriffshäufigkeit und Auftragsstruktur bestimmte Ablauforganisation umfasst die Kommissionierart und die Zonenorganisation. Die Betriebsorganisation steuert die Auftragsabwicklung in Abhängigkeit von Personalbedarf, Versandart und Systemleistung. [RN26a]; [VDI3590-1]

2.1.3 Grundprinzipien und Leistungsberechnung der Kommissionierung

Der folgende Abschnitt definiert die für diese Arbeit relevanten intralogistischen Grundprinzipien sowie die Begriffe Pick und Position. Die abschließende Aufschlüsselung der Kommissionierung in Zeitanteile verdeutlicht die zeitliche Gewichtung einzelner Arbeitsprozesse.

Grundprinzipien der Kommissionierung

Die grundlegenden Prinzipien der manuellen Kommissionierung unterscheiden sich in Bezug auf die Fortbewegung der kommissionierenden Person zwischen *Person-zur-Ware (PzW)* [Fra18, S. 14]; [HH06, S. 179] und *Ware-zur-Person (WzP)* [HH06, S. 316]; [HSD18, S. 56].

Tabelle 2.3 Taxonomie des Organisationssystems nach Teilsystemen [RN26a; VDI3590-1]

Teilsystem	Realisierungsmöglichkeit		
Aufbauorganisation	einzonig	mehrzonig	
		Zonung durch Technik	Zonung durch Organisation
Ablauforganisation	einstufig	zweistufig	
	auftragsseriell	auftragsparallel	
	zonenseriell	zonenparallel	
Betriebsorganisation	ohne Optimierung	mit Optimierung	

Bei der PzW-Kommissionierung bewegt sich die kommissionierende Person entweder zu Fuß oder mithilfe eines Unstetigförderer zum Lagerplatz, an dem die Entnahmeeinheit statisch bereitgestellt ist. Die entnommenen Artikel werden in einen Sammelbehälter gelegt und nach Abschluss des Kommissionierauftrags an einer festen Übergabestelle abgegeben [RN26a].

Im Gegensatz dazu wird bei der WzP-Kommissionierung die Bereitstelleinheit vom Lagerplatz zu einem definierten Kommissionierplatz transportiert. Die kommissionierende Person verbleibt dort weitgehend ortsfest und entnimmt die benötigten Artikel aus der Entnahmeeinheit. Anschließend wird die Bereitstelleinheit wieder an ihren Lagerplatz zurückgeführt. [HH06, S. 316]

Pick und Position

Der Begriff *Pick* bezeichnet den Zugriff auf einen Artikel sowie dessen Entnahme aus dem Lager. Er wird sowohl als Tätigkeit im Sinne eines Greifvorgangs als auch als Zähleinheit zur Erfassung der Entnahmehäufigkeit verstanden. Damit stellt der Pick eine zentrale Kennzahl zur Bewertung der Leistungsfähigkeit von Kommissioniersystemen dar.

Die *Position* ist hiervon zu unterscheiden. Sie beschreibt den Lagerort einer zu kommissionierenden Lagereinheit und entspricht einer Auftragszeile eines Kommissionierauftrags, die sämtliche für die Entnahme relevanten Informationen – etwa Lagerfach-ID, Artikel-ID, Artikelbezeichnung und Anzahl der Entnahmeeinheiten – enthält [VDI3590-1]; [Tom+10, S. 434 ff.]. Eine Position kann dabei mehrere Picks umfassen. In der Literatur wird hierfür ebenso der Begriff *Pickposition* verwendet [Fra18, S. 19 ff.].

Kommissionierzeitanteile

Die Kommissionierleistung ergibt sich aus dem Kehrwert der Kommissionierzeit. Diese setzt sich aus den Zeitanteilen *Wegzeit*, *Greifzeit*, *Basiszeit* und *Totzeit* zusammen [VDI4481]. Sie variieren je nach Systemtyp, Kommissionierprinzip und Automatisierungsgrad. Die folgenden Zeitanteile dienen der groben Orientierung.

Die *Wegzeit*, also die Fortbewegung zwischen den einzelnen Positionen [Tom+10, S. 19 f.], stellt mit 40–60 % den größten Anteil an der gesamten Kommissionierzeit dar [Tom+10, S. 432 f.]; [Sch03]. Sie ist der wichtigste Faktor zur Reduktion der Auftragsbearbeitungszeiten und Hauptfokus für Automatisierung.

Das Picken selbst, also die *Greifzeit* – bestehend aus Hinlangen, Aufnehmen, Befördern und Ablegen am Bereitstellplatz [RN26a] – macht 20–30 % der Kommissionierzeit aus [Tom+10, S. 432 f.]; [Sch03].

Die *Basiszeit* umfasst unter anderem das Sortieren von Belegen, die Aufnahme von Behältern sowie die Abgabe von Ware und Kommissionierbehältern [RN26a]. Mit etwa 10–20 % bildet sie den drittgrößten Zeitanteil [Tom+10, S. 432 f.]; [Sch03].

Als *Totzeit* wird unproduktive, jedoch nicht vollständig vermeidbare Zeit während der manuellen Kommissionierung bezeichnet. Dazu zählen unter anderem Lesen, Suchen, Identifizieren, Kontrollieren sowie das Öffnen von Verpackungen [RN26a]. Mit etwa 5–10 % weist sie den geringsten Anteil auf [Tom+10, S. 432 f.]; [Sch03].

2.1.4 Informationstechnische Führung in der Kommissionierung

Mit der Überführung von Kundenaufträgen in Kommissionieraufträge beginnt die informationsseitige Auftragsabwicklung. Die auftragsrelevanten Daten werden an die ausführende Person übermittelt [RN26a]. Zentrale Aufgabe der informationstechnischen Führung besteht darin, alle für die Entnahme notwendigen Daten bereitzustellen und zugleich eine Informationsüberlastung zu vermeiden. Zu den Pflichtangaben zählen die Anzahl der Entnahmeeinheiten und der Bereitstellort; optionale Angaben umfassen unter anderem Artikelbezeichnung, Kundeninformationen, Wegangaben oder Fehlmengen [RN26a]. Die Reihenfolge der Auftragspositionen bestimmt die Kommissionierroute.

Mit der Routenoptimierung und der übersichtlichen Weitergabe von Entnahmeinformationen verfolgt die informationstechnische Führung das Ziel, die Kommissionierleistung zu maximieren und gleichzeitig die Fehlerquote zu minimieren [HS07, S. 39]. Fehlkommissionierungen beeinträchtigen das Kundenvertrauen und verursachen finanzielle Verluste [HS07, S. 39]. Der finanzielle Verlust steigt mit zunehmender Entdeckungszeit des Fehlers: Wird

er erst beim Kunden festgestellt, liegen die Kosten laut [RGG12] etwa beim 8,4-Fachen gegenüber einer Entdeckung im Warenausgang.

Wie in Tabelle 2.4 dargestellt, wird die informationstechnische Führung grundsätzlich in papiergebundene (beleggebundene) und beleglose Verfahren unterteilt [Mar16, S. 408 f.]. Bei papiergebundenen Verfahren werden die Entnahmeinformationen über eine Kommissionier- bzw. Pickliste bereitgestellt [HSD18, S. 287]. Beleglose Verfahren umfassen stationäre Terminals, etwa fest installierte Monitore an Kommissionierstationen, Pick-by-Light (PbL)- und Put-to-Light (PtL)-Systeme sowie Geräte für die Mobile Datenerfassung (MDE). Zu letzteren zählen Pick-by-Voice (PbV)-Systeme und Handterminals [Mar16, S. 408 ff.]; [HS07, S. 40 ff.]; [RN26a]; [HSD18, S. 287 ff.].

Tabelle 2.4 Führung kommissionierender Personen [RN26a]

Verfahren zur Führung kommissionierender Personen				
papiergebunden	beleglos			
Pick-/Kommissionierliste	stationäre Terminals	Pick-by-light/Put-to-light	mobile Terminals	
	festinstallierte Monitore		online	offline
			Hand-terminal	Hand-terminal
			Pick-by-voice	

2.1.5 Systemtypen in der Kommissionierung

Die Klassifikation von Lager- und Kommissioniertechniken erfolgt unter dem Sammelbegriff *Systemtypen*. Differenziert wird nach dem Kommissionierprinzip (PzW, WzP) sowie nach dem Automatisierungsgrad (manuell, teil- oder vollautomatisiert).

In manuellen Systemen führen das Personal die zentralen Kommissioniervorgänge Bereitstellung, Fortbewegung, Entnahme und Abgabe vollständig aus (z. B. konventionelles Kommissionieren, Kommissioniernest, Kommissioniertunnel) [RN26a]; [HSD18, S. 278 f.]. Teilautomatisierte Systeme liegen vor, wenn mindestens ein Prozess maschinell unterstützt wird, etwa bei inverser Kommissionierung, Pick-to-Belt-Systemen, Vertikal-Umlaufregalen, Kommissionierstationen mit Behälterregalanbindung, dem Einsatz fahrerloser Transportfahrzeuge oder beim Kommissionieren im Hochregal [RN26a]; [HSD18, S. 280 f.].

Vollautomatisierte Systeme führen alle Vorgänge maschinell aus, beispielsweise durch Kommissionierroboter oder Schachtkommissionierer. Kombinationen manueller und vollautomatisierter Systeme werden zunehmend

als hybride Lösung eingesetzt. Dabei arbeiten Mensch und Roboter – anders als in teilautomatisierten Systemen – nicht gemeinsam an einem Kommissionierauftrag, sondern führen im selben Lagerbereich parallel identische Kommissioniervorgänge aus [Win+22].

Im Rahmen dieser Arbeit wird das konventionelle Kommissionieren betrachtet. Die kommissionierende Person bewegt sich mit einem Kommissionierwagen ebenerdig zu statisch und dezentral bereitgestellten Entnahmeeinheiten am Lagerplatz (z. B. Paletten, Fachboden- oder Durchlaufregale; siehe Abbildung 2.1) und entnimmt diese manuell. Die Führung erfolgt über die in Abschnitt 2.1.4 beschriebenen informationstechnischen Führungsverfahren. Häufig eingesetzt werden Pickliste, PbV, PbL und Handterminal, auch in Kombination (z. B. Pickliste plus PbL-Signalen an den Lagerfächern zur Leistungssteigerung und Fehlerreduktion). Nach Abschluss werden die Sammelbehälter an einem zentralen Übergabepunkt abgegeben. Das System zeichnet sich durch vergleichsweise geringe Investitionskosten und hohe Flexibilität hinsichtlich Artikelspektrum und Personaleinsatz aus. [RN26a]; [HSD18, S. 279]

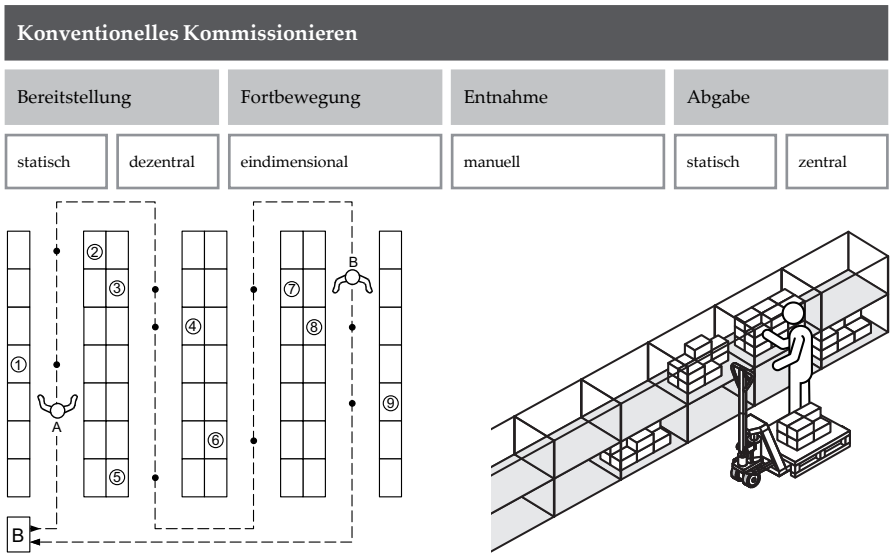
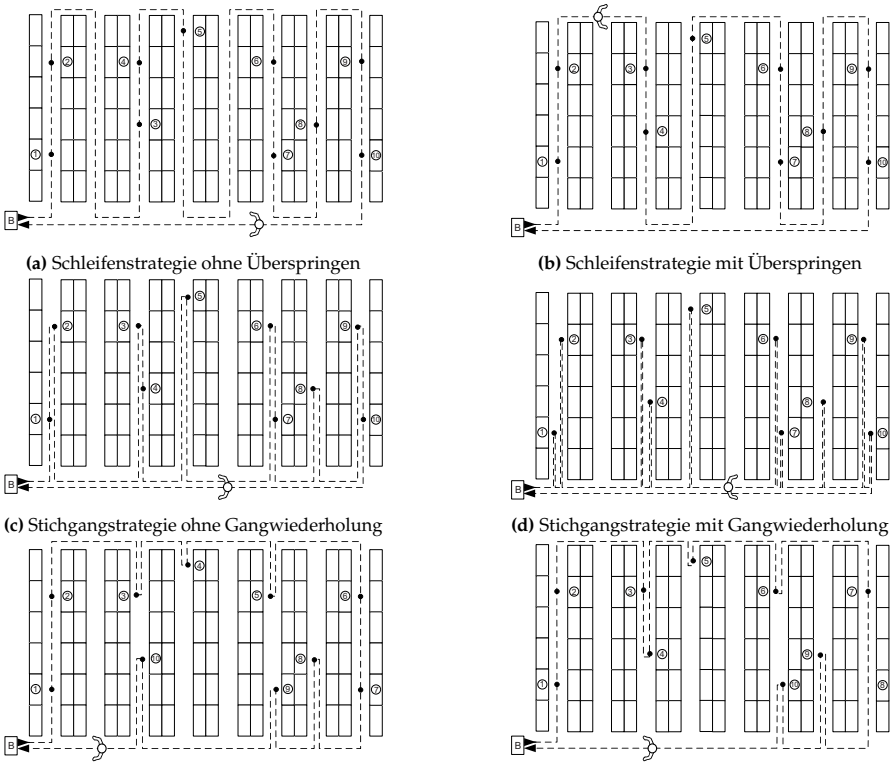


Abb. 2.1 Konventionelles Kommissionieren [RN26a]. Das B kennzeichnet die Basis. Die Zahlen stehen für die neun Positionen eines beispielhaften Kommissionierauftrags.

2.1.6 Wegstrategien bei eindimensionaler Fortbewegung

Charakteristisch für zahlreiche auf dem PzW-Prinzip beruhende Systemtypen – wie das konventionelle Kommissionieren – ist eine ebenerdige, eindimensionale Fortbewegungsstruktur. Da die Wegzeit gemäß Abschnitt 2.1.3 etwa 40–60 % der gesamten Kommissionierzeit ausmacht, stellt die Redu-

zierung der Wegstrecke einen wesentlichen Hebel zur Leistungssteigerung dar. Typische Heuristiken hierfür sind die *Schleifenstrategie* (mit und ohne Überspringen), die *Stichgangstrategie* (mit und ohne Gangwiederholung), die *Mittelpunkt-Heuristik* und *Largest-Gap-Heuristik* [RN26a]; [Fra18, S. 24 ff.]; [HSD18, S. 302]; [Sev+26; SN24]. Eine Übersicht dieser Wegstrategien ist in Abbildung 2.2 als Draufsicht dargestellt.



(a) Schleifenstrategie ohne Überspringen

(b) Schleifenstrategie mit Überspringen

(c) Stichgangstrategie ohne Gangwiederholung

(d) Stichgangstrategie mit Gangwiederholung

(e) Mittelpunkt-Heuristik

(f) Largest-Gap-Heuristik

Abb. 2.2 Wegstrategien bei eindimensionaler Fortbewegung [RN26a]

Bei der *Schleifenstrategie* werden die Gassen mäanderförmig durchlaufen [HH11]. Ohne Überspringen werden alle Gassen unabhängig von der Lage der Picks begangen – sinnvoll bei vielen Positionen je Auftrag, fehlender Gegenverkehrsmöglichkeit oder gewünschter Planungsvereinfachung [Gud05]. Mit Überspringen werden dagegen Gassen ohne Pickposition ausgelassen, wodurch sich der Weganteil pro Position reduziert. [RN26a]; [Fra18, S. 25 f.]

Bei der *Stichgangstrategie* werden nur Gassen betreten, in denen sich Positionen befinden, und auf derselben Seite wieder verlassen. Ohne Gangwiederholung wird jede Gasse höchstens einmal pro Auftrag betreten; mit Gangwiederholung erfolgt ein erneutes Betreten für jede Position, wenn et-

wa die Gassenbreite die Nutzung eines Kommissionierwagens nicht zulässt [Gud05; RN26a]; [Fra18, S. 24 f.].

Die *Mittelpunkt-Heuristik* stellt eine Sonderform der Stichgangstrategie dar: Die Gassen werden gedanklich halbiert. Die erste und letzte Gasse werden vollständig durchlaufen, alle übrigen nur bis maximal zur Mitte betreten. Diese Strategie ist insbesondere bei zugriffshäufigkeitsorientierter Lagerplatzvergabe sinnvoll, bei der schnell drehende Artikel nahe den Gangwechselwegen und selten benötigte Artikel in der Gangmitte liegen. [RN26a]; [Fra18, S. 25 f.]

Die *Largest-Gap-Heuristik* folgt demselben Grundprinzip, ersetzt jedoch die feste Gangmitte durch die größte positionsfreie Strecke innerhalb eines Ganges. Die Gasse wird nur bis zu dieser *größten Lücke* betreten, wodurch der Gesamtweg minimiert wird. [RN26a]; [Fra18, S. 26 ff.]

2.2 Zeitwirtschaft

Die Anforderungen an die Intralogistik unterliegen einem fortlaufenden Wandel infolge externer Einflüsse. Pandemien, die Havarie eines Containerschiffs im Suezkanal, die Halbleiterkrise sowie geopolitische Konflikte erhöhten den Bedarf an resilienten Supply Chains, was sich unmittelbar auf das Lagerwesen auswirkt. Der wachsende E-Commerce [Eur22b], kürzere Produktlebenszyklen [LB06] und der Trend zur Same-Day-Delivery [VCT19] rücken Logistikdienstleister näher an den Endkunden und führen zu kleineren Auftragsgrößen, hohen Retourenquoten und kurzen Lieferzeitfenstern [DC22; WW25].

Dadurch verschiebt sich der Leistungsfokus intralogistischer Dienstleister von der reinen Flächen- und Bestandsbewirtschaftung hin zur prozessualen Abwicklungsgeschwindigkeit einzelner Aufträge. Eine zentrale Kenngröße bildet dabei die Zeit mit Angaben zu Dauer, Häufigkeit und Reihenfolge manuell ausgeführter Tätigkeiten, da sich hieraus die Abwicklungsgeschwindigkeit eines Lagers ableiten lässt. Dessen systematische Erfassung, Analyse und Bewertung sind Voraussetzung für das Verständnis und die Optimierung von Arbeitsprozessen.

Definition: *Zeitwirtschaft und Zeitdaten*

Die Zeitwirtschaft ist für die Bewirtschaftung von sogenannten Zeitdaten zuständig und umfasst die Planung und Durchführung einer Datenermittlung sowie deren Auswertung, Aufbereitung, Nutzung und Pflege [SBL18, S. 573 ff.]. Unter Zeitdaten werden Zeitwerte, -punkte und -intervalle sowie Merkmale und Einflussgrößen verstanden [Ero17, S. 6].

2.2.1 Bedeutung der Zeitwirtschaft für die Planung und Optimierung in der Intralogistik

Trotz steigender Automatisierung bestehen in mittelständischen Unternehmen 47 % aller innerbetrieblichen Materialflussprozesse aus manuellen Tätigkeiten [Ant20]. DHL Paket GmbH gibt an, dass 80 % ihrer Lagerhäuser rein manuell, 15 % mit Förderbändern, Sortieranlagen oder anderen Geräten mechanisiert und 5 % automatisiert sind [Bon16, S. 22]. Selbst in den automatisierten Lagerhäusern von DHL, welche als hochmechanisiert betrachtet werden, nehmen Menschen bei zum Beispiel Be- und Entladevorgängen von Lkw eine wichtige Rolle ein [Bon16, S. 22]. Speziell in der Kommissionierung ist insbesondere die Handhabung von Artikeln stark manuell geprägt. Zu diesen Tätigkeiten gehören unter anderem das Picken, das Quittieren, das Konsolidieren und das Verpacken [Kor+25]. Die zeitliche Erfassung und Einordnung dieser manuellen Tätigkeiten in kontextuellen Prozessschritten bilden die Grundvoraussetzung für die Analyse bestehender und die Planung neuer Arbeitsabläufe. In der Kommissionierung werden im Rahmen der Zeitwirtschaft insbesondere Weg-, Greif-, Basis- und Totzeiten ermittelt. Die Zeitdaten dienten unter anderem der Personalbemessung, der Lagerplanung und -steuerung, der Leistungsbeurteilung sowie der Investitions- und Kapazitätsplanung (siehe Abbildung 2.3). Sie wird erst dann nutzbar, wenn sie nicht losgelöst, sondern eingebettet in einer betrieblichen Anwendung betrachtet wird [Olb93, S. 19].

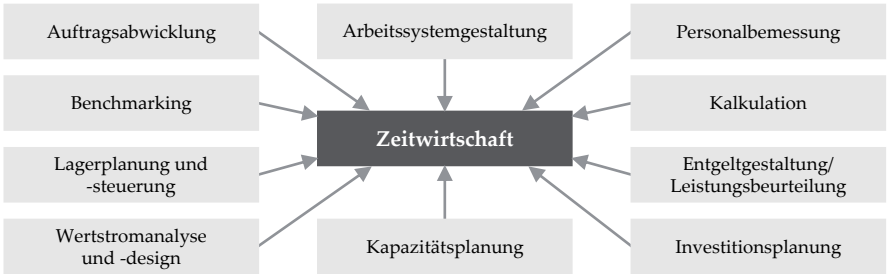


Abb. 2.3 Anwendungsbereiche der Zeitwirtschaft [Bin10, S. 855]; [LDL16, S. 187]; [Olb93, S. 19]

Trotz der Verfügbarkeit etablierter Methoden der Zeitdatenermittlung, die in den folgenden Abschnitten erläutert werden, greifen Unternehmen häufig auf interne Erfahrungswerte, grobkörnige Schätzungen oder selbst entwickelte Ansätze zurück [Gud10, S. 869]; [AMW10]; [WS14]. Teilweise wird sogar vollständig auf zeitwirtschaftliche Methoden verzichtet. Dies ist insbesondere auf den erheblichen Zeit- und Kostenaufwand zurückzuführen, der mit der Erfassung und Auswertung von Zeitdaten verbunden ist.

2.2.2 Zeitwirtschaftliche Methoden zur Soll- und Ist-Zeitermittlung

Die Zeitwirtschaft geht auf die Arbeiten von F. W. Taylor (1856–1915) und F. B. Gilbreth (1868–1924) zurück. Taylor entwickelte mit der Zerlegung von Arbeitsprozessen in wiederkehrende Ablaufabschnitte und deren zeitlicher Erfassung den Vorläufer der heutigen Zeitstudie [Tay22]. Gilbreth ergänzte diesen Ansatz durch systematische Bewegungsstudien, aus denen die Grundlagen der Planzeitermittlung hervorgingen [HO94].

Darauf aufbauend haben sich Methoden zur Ermittlung von Ist- und Sollzeiten weiterentwickelt, die heute – neben Sonderformen wie Befragen, Vergleichen oder Simulieren – in kontinuierliche Beobachtung, Stichprobenbeobachtung und rechnerisch-analytische Verfahren gegliedert werden [SBL18, S. 578] (siehe Tabelle 2.5).

Zur kontinuierlichen Beobachtung zählen die manuelle Zeitstudie sowie automatische Methoden der menschlichen Aktivitätserkennung (engl. HAR, [Rei21]). Die Multimomentaufnahme gehört zur Stichprobenbeobachtung. Alle drei Ansätze dienen der Ermittlung von Ist-Zeiten eines physisch existierenden Systems [LDL16, S. 191]; [REF97, S. 348].

Ist-Zeiten sind die „tatsächlich vom Menschen oder Betriebsmitteln gebrauchten Zeiten für die Ausführung bestimmter Ablaufabschnitte“ [REF97, S. 62]. Sie werden als Fremdaufschreibung durch eine beobachtende Person bzw. Sensoren oder als Selbstaufschreibung durch die ausführende Arbeitskraft gemessen.

Rechnerisch-analytische Methoden, wie das Berechnen oder Zusammensetzen, dienen hingegen der Bestimmung von Soll-Zeiten. „Die Soll-Zeit kennzeichnet die Zeit, die für den geplanten Ablauf eines Prozesses erwartet wird“ [REF21, S. 84]. Zu den Methoden der Soll-Zeiten-Ermittlung zählen Systeme vorbestimmter Zeiten (SvZ) wie Methods-Time Measurement (MTM), Work Factor und Maynard Operations Sequence Technique [SBL18, S. 578]. Soll-Zeiten sind aufbereitete Ist-Zeiten [VDI4481, S. 13] (siehe Abbildung 2.4). Ein physisch existierendes System ist keine Voraussetzung zur Bestimmung von Soll-Zeiten, sofern Ist-Zeiten aus vergleichbaren Systemen oder Arbeitsabläufen vorliegen. Liegen zeitbestimmende Einflussgrößen und die Arbeitsbedingungen vor, werden aus Soll-Zeiten Planzeiten für bestimmte wiederholende Arbeitsablaufabschnitte abgeleitet [LDL16, S. 191]; [Sac09, S. 41]; [REF97, S. 348]; [HO94, S. 25]. Durch die Addition von Zeitzuschlägen werden aus Soll-Zeiten Vorgabezeiten für Mitarbeiter und Betriebsmittel. Während die Vorgabezeiten für Betriebsmittel aus Grund- und Verteilzeiten bestehen, werden für den Mitarbeiter zusätzlich Erholungszeiten dazuaddiert [REF97, S. 41].

In der praktischen Anwendung dominieren die *manuelle Zeitstudie*, die *Multimomentaufnahme* und *MTM* [BL12, S. 94]; [Bar+13, S. 429 ff.]; [LDL16,

Tabelle 2.5 Methodenüberblick der Zeitdatenermittlung [Olb93, S. 25]; [REF97, S. 61 ff.]; [Hei97, S. 23]; [Sac09, S. 36]; [Deu+16, S. 196 f.]; [Gum+17, S. 163]; [Rei21]; [REF21, S. 10]

Ist-Zeit		
Befragen		Messen
		Zeitstudie
		Multimomentaufnahme
		Menschliche Aktivitätserkennung

Soll-Zeit		
Bestimmen		Vereinbaren
Berechnen		
Vergleichen und Schätzen		
Simulieren		
Zusammensetzen	Planzeitbausteine	
	Work Factor	
	Methods-Time Measurement	
	Maynard Operations Sequence Technique	

S. 198]. Die *menschliche Aktivitätserkennung* stellt eine automatisierte Form der Zeitdatenermittlung dar, die insbesondere den hohen manuellen Erfassungsaufwand sowie die eingeschränkte Objektivität klassischer Methoden adressiert. Diese vier Methoden werden in den folgenden drei Abschnitten näher erläutert.

2.2.3 Manuelle Methoden der Ist-Zeitdatenmessung

In Produktion und Intralogistik kommen zur Messung von Ist-Zeiten beobachtungsbasierte Methoden wie die *Multimomentaufnahme* und die *Zeitstudie* zum Einsatz, die sich sowohl in ihrer Erhebungsart als auch im damit verbundenen Aufwand unterscheiden.

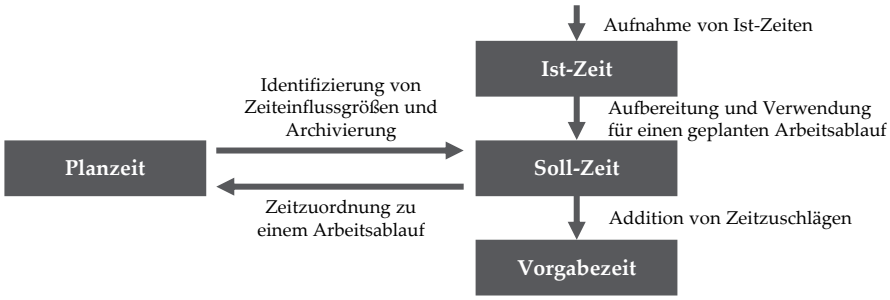


Abb. 2.4 Zusammenhang von Ist-, Soll-, Plan- und Vorgabezeiten [Deu+16, S. 190]

Multimomentaufnahme

Die Multimomentaufnahme ist ein statistisches Stichprobenverfahren zur Ermittlung von Ist-Zeiten innerhalb eines definierten Beobachtungszeitraums [Olb93, S. 26 f.]; [REF97, S. 232]. Voraussetzung ist ein physisch existierendes Beobachtungssystem. In zufällig gewählten Zeitintervallen erfasst der Beobachter während mehrerer Rundgänge an festgelegten räumlichen Punkten die zuvor definierten Ablaufarten [Fri16, S. 104 ff.]. Die Datenerhebung erfolgt entweder als Fremdaufschreibung durch eine externe Person oder als Selbstaufschreibung durch den Mitarbeiter [REF21, S. 47 f.]; [SBL18, S. 581].

Es werden zwei Ausprägungen unterschieden: das Multimoment-Häufigkeits-Zählverfahren und das Multimoment-Zeit-Messverfahren (siehe Tabelle 2.6). Beim Häufigkeits-Zählverfahren werden die absoluten und prozentualen Anteile der beobachteten Ablaufarten ermittelt, typischerweise mittels Strichlisten über mehrere Rundgänge [Fri16, S. 105 ff.]; [SBL18, S. 582 ff.]. Das Zeitmessverfahren folgt demselben Stichprobenprinzip, erfasst jedoch anstelle von Zählwerten Zeitwerte (z. B. in Minuten oder Stunden) [Fri16, S. 116 ff.]; [SBL18, S. 585 ff.].

Tabelle 2.6 Gliederung des Multimomentverfahrens [Hal69, S. 18]

Grundverfahren	Multimomentverfahren			
praktische Verfahren	Multimoment-Häufigkeitszählverfahren		Multimoment-Zeitmessverfahren	
Ergebnisse	Zählwerte		Messwerte	
	absolute Häufigkeit	Prozentsätze	Minutenwerte	Stundenwerte

Zeitstudie

Die Zeitstudie, auch Zeitaufnahme oder REFA-Zeitstudie genannt, ist ein kontinuierliches Messverfahren zur Ermittlung von Ist-Zeiten [Olb93, S. 26 ff.].

Aufgrund ihres methodischen Aufwands wird sie überwiegend als Fremdaufschreibung durchgeführt und in der Literatur teilweise mit diesem Begriff gleichgesetzt.

Im Rahmen der Durchführung begleitet ein externer Beobachter den Mitarbeiter und ordnet dessen Tätigkeiten unmittelbar zuvor definierten Ablaufabschnitten zu. Diese entsprechen strukturierten, zielgerichteten Handlungseinheiten im Sinne der in dieser Arbeit verwendeten Prozessdefinition (siehe Kapitel 1). Für jeden Ablaufabschnitt werden Ist-Zeit, Leistungsgrad, Einflussgrößen und Bezugsmengen erfasst [REF97, S. 81]. Die Zeitmessung erfolgt in der Regel mittels Stoppuhr und wird auf Zeitaufnahmebögen dokumentiert. Eine valide Beurteilung des Leistungsgrads je Ablaufabschnitt in Kombination mit der Zeitmessung setzt eine Mindestdauer von 15 Sekunden pro Abschnitt voraus [REF97, S. 146]; [REF13, S., 252]. Von dieser Dauer hängt außerdem die relative Messgenauigkeit ab: Mit abnehmender Ablaufabschnittdauer verringert sich die relative Messgenauigkeit. Bei kürzeren Ablaufabschnitten ist eine leistungsgradbezogene Einzelbewertung je Messung nicht praktikabel. In solchen Fällen erfolgt die Leistungsgradbewertung zusammengefasst, entweder einmal oder in periodischen Abständen je Ablaufabschnitt, einmal je Vorgang oder einmal je vollständigem Zyklus [REF97, S. 146].

Die Abfolge der Ablaufabschnitte kann unterschiedlich strukturiert sein. Unterschieden werden zyklische, reihenweise, unregelmäßige und wechselnde Ablauffolgen [Fri16, S. 60 f.]. In der Praxis treten diese Formen häufig kombiniert auf.

Zur Überführung der erfassten Ist-Zeiten in Soll-Zeiten ist eine Bewertung des Leistungsgrads erforderlich – die in Abbildung 2.5 als Addition von Zeitzuschlägen dargestellt ist [Fri16, S. 81]; [REF21, S. 42]. Da Zeitstudien aufgrund des hohen Erfassungsaufwands meist auf einem vergleichsweise kleinen Zeitraum und wenigen beobachteten Mitarbeitern beruhen, ist es nicht möglich, die gemessenen Zeiten unmittelbar auf die gesamte Belegschaft zu übertragen. Der Leistungsgrad wird durch die beobachtende Person eingeschätzt und stellt damit den subjektivsten Bestandteil der Methode dar. Er setzt sich aus der Intensität der Ausführung – bestimmt durch Bewegungsgeschwindigkeit und Kraftanspannung – sowie der Wirksamkeit im Sinne der Qualität der Arbeitsweise zusammen [Fri16, S. 48]. REFA weist darauf hin, dass diese Merkmale in der Praxis nicht immer eindeutig voneinander abgrenzbar sind [REF97, S. 128]. Schlussfolgernd lassen sich für die REFA-Zeitstudie drei zentrale Defizite identifizieren:

- Hoher Aufwand infolge der manuellen Datenerfassung
- Eingeschränkte Skalierbarkeit, da die Erfassung auf einzelne Mitarbeiter sowie kurze Beobachtungszeiträume beschränkt ist
- Potenzielle subjektive Verzerrungen bei der Leistungsgradbewertung

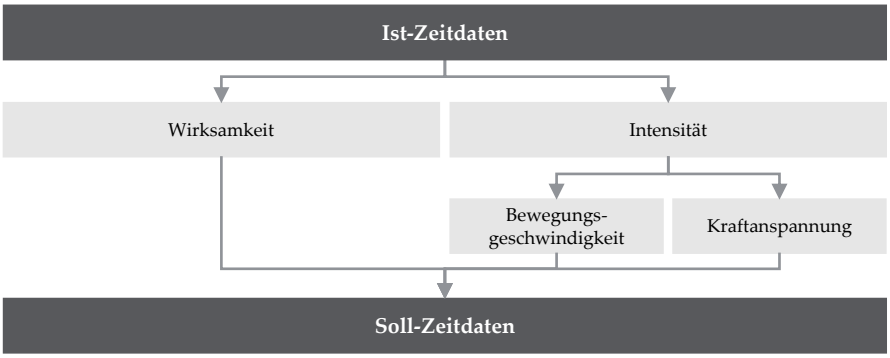


Abb. 2.5 Soll-Zeitdatenbestimmung nach dem Leistungsgradprinzip [REF97, S. 125 ff.]

2.2.4 Menschliche Aktivitätserkennung als automatisierte Methode der Ist-Zeitdatenmessung

Die zuvor beschriebenen Verfahren der Zeitdatenerfassung basieren auf manueller Beobachtung und Bewertung menschlicher Tätigkeiten. Sie ermöglichen zwar eine strukturierte Arbeitsanalyse, sind jedoch aufwändig in der Durchführung, weshalb sie meist nur zeitlich begrenzt eingesetzt werden. Zudem sind sie stark vom Beobachter abhängig. Vor diesem Hintergrund wird eine automatisierte Erfassung von Arbeitsschritten angestrebt, um mit geringem Erhebungsaufwand eine breite und kontinuierliche Datenbasis für den Vergleich unterschiedlicher Systemtypen und Strategien zu schaffen.

Einen solchen Ansatz stellt die menschliche Aktivitätserkennung (HAR) dar. HAR bezeichnet die automatische Klassifikation menschlicher Tätigkeiten anhand von Sensordaten [AAA21, S. 2 ff.]. Dabei werden beispielsweise Bild-, Video- oder inertiale Bewegungsdaten mittels KI-Methoden verarbeitet [CJK17], um vordefinierte Aktivitätsklassen zu identifizieren (siehe Abbildung 2.6). Die sensorbasierte Erfassung ermöglicht somit eine kontinuierliche, maschineninterpretierbare Abbildung realer Arbeitsabläufe.

Definition: *Menschliche Aktivität*

Im Rahmen von HAR wird die menschliche Aktivität als jede durch Skelettmuskeln des Torsos und der Gliedmaßen erzeugte Körperbewegung verstanden, die eine Zielgröße der Erkennung bzw. der Klassifikation darstellt (angelehnt an [CPC85; Lar+12; Rei+18a; Sou+19]).

Die Aktivitätserkennung umfasst vier grundlegende Schritte: Modelltraining, Datenaufnahme, Datenvorverarbeitung und Klassifikation.

Schritt 1: Modelltraining

Die Aktivitätserkennung basiert in der Regel auf überwachten Lernverfahren. Hierzu werden aufgezeichnete Sensordaten segmentiert und mit Aktivitätslabels annotiert. Die Erstellung solcher Trainingsdaten ist mit erheblichem manuellem Aufwand verbunden. Auf Basis dieser gelabelten Daten wird ein Klassifikationsmodell trainiert, das die Zusammenhänge zwischen Sensordaten und Klassenlabels erlernt [Bel20, S. 3 f.]; [SB14, S. 22–24]. In der Praxis kommen hierfür häufig neuronale Netze zum Einsatz [Rei+19a]. Das Modelltraining stellt eine vorgelagerte Voraussetzung dar. Erst auf Basis eines trainierten Modells lässt sich die in Abbildung 2.6 dargestellte Verarbeitungskette auf kontinuierlich erfasste Sensordaten anwenden.

Schritt 2: Datenaufnahme

Im zweiten Schritt werden Bewegungsdaten erfasst (siehe unterste Ebene in Abbildung 2.6). In industriellen Arbeitsumgebungen werden hierfür überwiegend körpergetragene Inertial Measurement Units (IMUs) eingesetzt. Diese Systeme enthalten triaxiale Inertialsensoren, die translatorische und rotatorische Beschleunigungen entlang dreier Raumachsen messen. Aufgrund ihrer kompakten Bauweise, Robustheit und Unabhängigkeit von externer Infrastruktur sind sie besonders für den praktischen Einsatz geeignet.

Typischerweise werden mehrere Sensoren gleichzeitig verwendet, die beispielsweise an den Extremitäten oder der Hüfte angebracht sind, um die für industrielle Tätigkeiten charakteristischen Arm- und Fortbewegungsaktivitäten zu erfassen. Ergänzend kommen teilweise Beacons oder 5G-basierte Systeme zur Indoorlokalisierung sowie Kameras zur Unterstützung der Annotation zum Einsatz. In der Forschung werden darüber hinaus weitere Sensortypen genutzt, etwa Magnetometer, Global Positioning System (GPS) oder Herzfrequenzsensoren, um zusätzliche Zeitreiheninformationen zu erfassen [CJK17].

Ein konkretes industrielles Anwendungsbeispiel stellt das System der MotionMiners GmbH dar. Hierbei wird pro Mitarbeiter ein Wearable Set aus drei Geräten eingesetzt, die an beiden Handgelenken und an der Hüfte getragen werden. Die Geräte erfassen Bewegungsdaten mittels integrierter IMUs sowie über Bluetooth-Signale der Umgebung. Im Lager installierte Beacons ermöglichen eine Indoorlokalisierung [Fel18]. Für die Aktivitätserkennung dienen primär die IMU-Daten; durch die Ergänzung um räumlichen Kontext lassen sich die erkannten Aktivitäten anschließend spezifischen Zonen zuordnen.

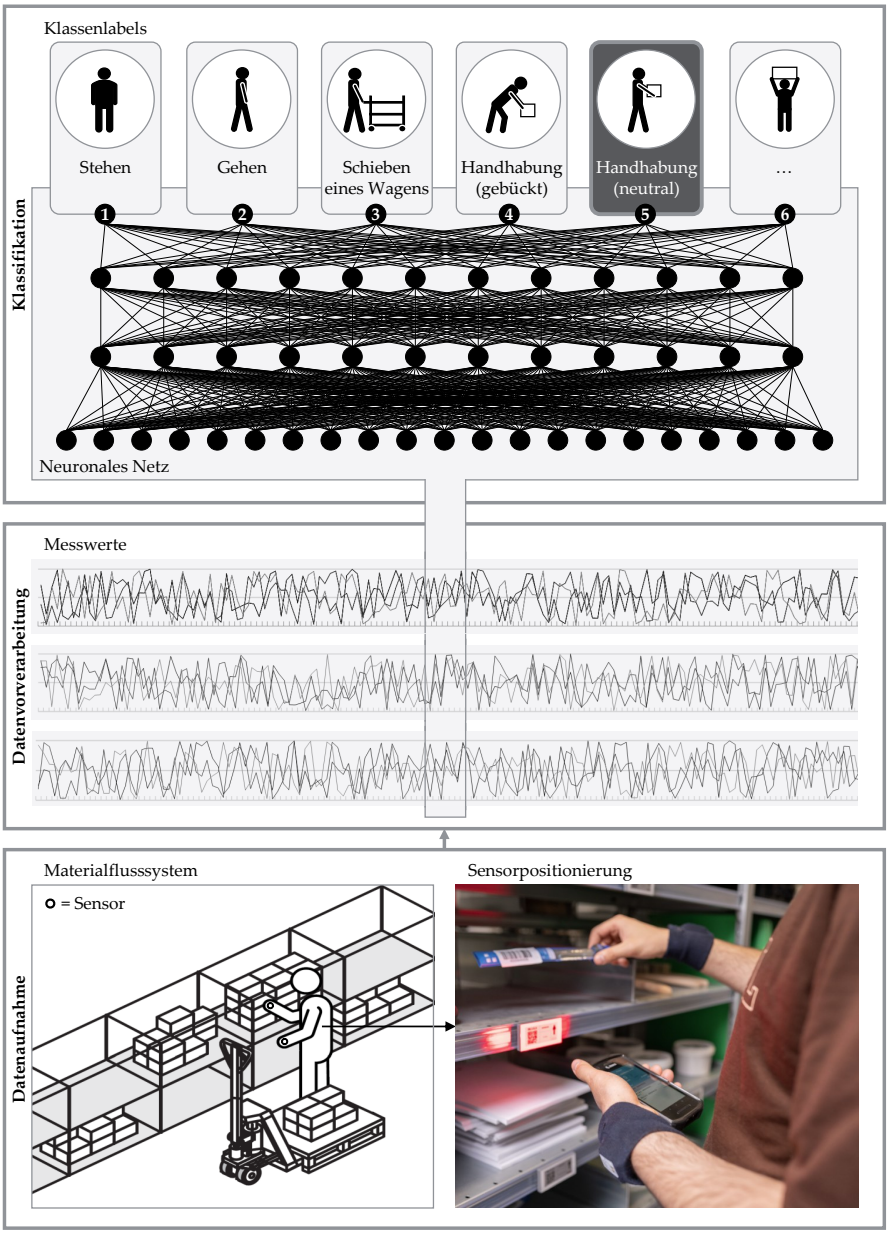


Abb. 2.6 Exemplarische Verarbeitungskette der Aktivitätserkennung. Die dargestellten Sensorpositionen, Sensortypen, Messgrößen, Netzwerkarchitektur sowie Klassenlabels sind illustrativ und variieren je nach Anwendung. Die in den Schweißbändern integrierten IMUs (siehe unten rechts) stammen von der MotionMiners GmbH.

Schritt 3: Datenvorverarbeitung

Im dritten Schritt erfolgt die Vorverarbeitung der Rohdaten, die typischerweise Rauschreduktion, Normierung sowie die Segmentierung in Zeitfenster fester Länge umfasst (siehe mittlere Ebene in Abbildung 2.6).

Schritt 4: Klassifikation

Im letzten Schritt werden die vorverarbeiteten Segmente durch das trainierte Modell analysiert und jeweils einer vordefinierten Aktivitätsklasse zugeordnet (siehe oberste Ebene in Abbildung 2.6). Im Gegensatz zur REFA-Zeitstudie ermöglicht dieses Vorgehen bereits bei sehr kurzen Bewegungsabschnitten von etwa 0,5 Sekunden eine automatisierte Klassifikation bei gleichzeitig konstanter Messgenauigkeit.

Die Wahl geeigneter Klassenlabels ist stark anwendungsabhängig. Insbesondere kurze und komplexe Tätigkeiten sind schwer zuverlässig zu erkennen, weshalb in industriellen Anwendungen meist einfache, bewegungsbasierte Klassen verwendet werden. Diese sind menschenzentriert definiert und lassen sich anhand charakteristischer Bewegungsmuster identifizieren, etwa Stehen, Gehen, Schieben eines Wagens oder Handhabungstätigkeiten. Neben arbeitswirtschaftlichen Analysen dienen solche Klassen auch niederschwelligen Ergonomiebewertungen sowie der Erkennung von Überbelastungen.

Definition: *Klassenlabel*

Klassenlabels sind annotierbare diskrete Kategorien, die zu einem Zeitpunkt oder innerhalb eines Zeitintervalls auftreten, unabhängig von ihrer späteren Verwendung im Klassifikationsverlauf. Sie beinhalten sowohl menschliche Körperbewegungen als auch kontextuale Informationen.

2.2.5 Soll-Zeitdatenbestimmung mit MTM

Unter den Verfahren zur Bestimmung von Soll-Zeitdaten hat sich das MTM als eines der am weitesten verbreiteten Verfahren etabliert. Als Verfahren der SvZ zerlegt MTM menschliche Tätigkeiten in elementare Bewegungsanteile [Gum+17, S. 189]. Jedem dieser Bewegungselemente werden – abhängig von Einflussgrößen wie Bewegungslänge, Bewegungsgenauigkeit, Masse des bewegten Objekts oder Bewegungsfall – standardisierte Zeitwerte zugeordnet [REF95, S. 289]; [MTM26]. Diese Zeitbausteine sind für jedes MTM-Bausteinsystem in Normzeitkarten (MTM-Datenkarten) dokumentiert [MTM26]. Die MTM-Bausteinsysteme variieren sowohl im Methodenniveau als auch in der Analysiergeschwindigkeit [Kuh+23, S. 12]. Einen zusammenfassenden Überblick über die verschiedenen MTM-Bausteinsysteme zeigt Abbildung 2.7 und die folgende Auflistung:

- MTM-1 (MTM-Grundsystem)
- MTM-2
- MTM-Standarddaten (SD)
- MTM-HWD (Human Work Design)
- MTM-Universelles Analysiersystem (UAS)
- MTM-Mehrzweck-Einzel- und Kleinserienfertigung (MEK)
- MTM-LOG (MTM-Logistik)
- MTM-OS (MTM-Office-System)

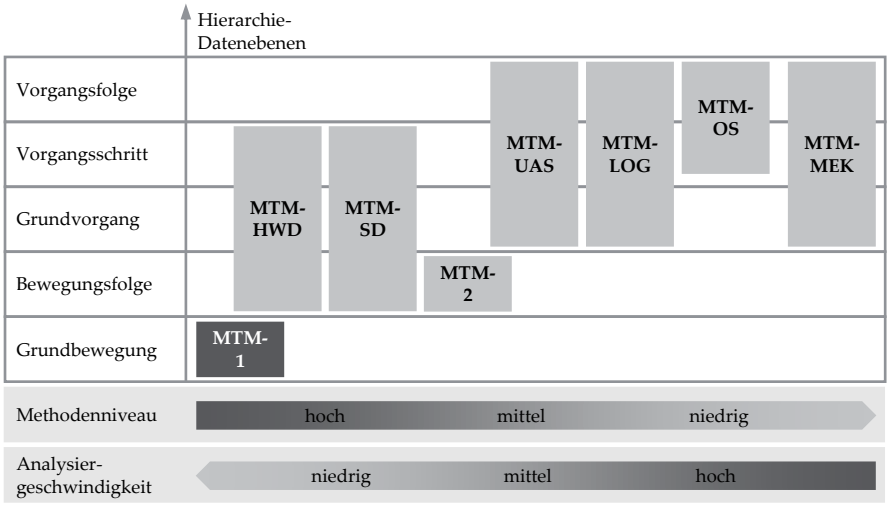


Abb. 2.7 MTM-Bausteinsysteme im Überblick [Kuh+23, S. 12]; [HO94, S. 44]

Das Grundsystem MTM-1 strukturiert Bewegungen des Menschen anhand der fünf Elementarzyklen des Hand-Arm-Systems: Hinlangen, Greifen, Bringen, Fügen und Loslassen (siehe Tabelle 2.7) [LDL16, S. 198 ff.]. Diese bilden den überwiegenden Anteil der Greifzeiten in der Kommissionierung sowie der Handhabungszeiten beim Verpacken. Die Wegzeiten der Kommissionierung werden dagegen durch Zeitbausteine von Ganzkörper-, Bein- und Fußbewegungen beschrieben. Mit durchschnittlichen Bausteindauern von etwa 0,288 Sekunden lassen sich Arbeitsprozesse und deren Einflussgrößen sehr detailliert modellieren. Der hohe Detailgrad, der in Abbildung 2.7 durch das Methodenniveau dargestellt wird, führt jedoch zu erheblichem Analyseaufwand: Für die Auswertung einer einminütigen Aufnahme benötigt ein erfahrener Analyst rund 200 Minuten [LDL16, S. 199]. Dieser Aufwand ist mit der Erstellung von Trainingsdatensätzen in der HAR vergleichbar.

Zur Reduzierung des Analyseaufwands wurden die Grundbewegungen von MTM-1 zu weiteren Bausteinsystemen zusammengefasst [LDL16, S. 198 ff.]. Durch die Aggregation feingliedriger Bewegungen zu Bewegungsfolgen, Grundvorgängen, Vorgangsschritten und vollständigen Vorgangsfol-

Tabelle 2.7 Grundbewegungen bei MTM-1 [BL12, S. 96]; [HO94, S. 45]

Grundbewegungen bei MTM-1				
Bewegungen des Hand-Arm-Systems		Blickfunktion	Ganzkörper-, Bein- und Fußbewegungen	
Elementarzyklus	Hinlangen	Blick verschieben	Körperachse nicht verlagern	Fußbewegung
	Greifen	Prüfen		Beinbewegung
	Bringen		Körperachse verschieben	Seitenschritt
	Fügen			Körperdrehung
	Loslassen			Gehen
weitere Bewegungen	Drücken		Körperachse neigen	Beugen & Aufrichten
	Trennen			Bücken & Aufrichten
	Drehen			Knien & Aufrichten
				Setzen & Aufrichten

gen sinkt zwar der Detailgrad, gleichzeitig reduziert sich jedoch die benötigte Analysezeit [Kuh+23, S. 12]. So verringert sich der Analyseaufwand von etwa 200 Minuten bei MTM-1 auf rund 10 Minuten bei MTM-MEK, was auf die Vergrößerung der mittleren Zeitbausteine von 0,288 Sekunden auf 3,6 Sekunden zurückzuführen ist [LDL16, S. 198 ff.]. Die aggregierten Bausteinsysteme sind jeweils spezifischen Einsatzfeldern zugeordnet: MTM-MEK wird vor allem in der Einzel- und Kleinserienfertigung verwendet, während MTM-Logistik (LOG) standardisierte logistische Tätigkeiten beschreibt, z. B.:

- Verpackung öffnen und schließen,
- Fortbewegung mit Handgabelhubwagen und Transportwagen,
- Staplerhandhabung,
- Handhabung von Teilen, Kartons, Behältern und
- Verarbeitung von Informationen [MTM26]; [Kuh+23, S. 14 ff.].

Eine SvZ-Analyse erfolgt grundsätzlich auf eine dieser zwei Arten: Entweder wird ein Arbeitssystem auf Basis eines geplanten Ablaufes beschrieben (Planungsanalyse), oder es erfolgt die Untersuchung anhand der Beobachtung eines real ausgeführten Arbeitsprozesses (Beobachtungsanalyse) [Sad07, S. 85]. Letztere ist mit der manuellen Annotation von Sensordaten im Rahmen der HAR vergleichbar (siehe Abschnitt 2.2.4).

Kapitel 3
Limitationen bestehender Forschungsarbeiten auf dem Gebiet der menschlichen Aktivitätserkennung

Zusammenfassung Das dritte Kapitel analysiert den aktuellen Forschungsstand der menschlichen Aktivitätserkennung im Hinblick auf ihre Eignung zur Erkennung intralogistischer Arbeitsprozesse. Die betrachteten Ansätze ermöglichen eine granulare Erkennung von Aktivitäten, ordnen diese jedoch nicht in wiederkehrende Arbeitsabläufe ein und erlauben damit keine Erkennung von Prozessen im Sinne arbeitswissenschaftlicher Zeitstudien. Die Auswertung vorhandener Datensätze zeigt zudem, dass keine geeignete Datengrundlage existiert, die gleichzeitig Bewegungs-, Kontext- und Prozessinformationen enthält und eine systematische Untersuchung neuer Ansätze ermöglicht. Aus der Analyse des Forschungsstandes ergibt sich daher die Notwendigkeit einer Datengrundlage sowie eines darauf aufbauendes Verfahren zur aktivitäts- und kontextsensitiven Prozesserkennung.

Dieses Kapitel basiert teilweise auf den folgenden Veröffentlichungen:

Christopher Reining u. a. „Human Activity Recognition for Production and Logistics—A Systematic Literature Review“. In: *Information* (2019). DOI: 10.3390/info10080245

Friedrich Niemann u. a. „LARa: Creating a Dataset for Human Activity Recognition in Logistics Using Semantic Attributes“. In: *Sensors* (2020). DOI: 10.3390/s20154083

Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 03) – A Motion Capture and Inertial Measurement Dataset*. 2023. DOI: 10.5281/ZENODO.8189341

Friedrich Niemann u. a. „DaRA Dataset: Combining Wearable Sensors, Location Tracking, and Process Knowledge for Enhanced Human Activity and Human Context Recognition in Warehousing“. In: *Sensors* (2026). DOI: 10.3390/s26020739

Friedrich Niemann u. a. „Towards Standardized Dataset Creation for Human Activity Recognition: Framework, Taxonomy, Checklist, and Best Practices“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_5

3.1 HAR als Methode der Ist-Zeitdatenermittlung

Nachdem HAR in Abschnitt 2.2.4 als automatisierte Methode zur Ermittlung von Ist-Zeiten in der Intralogistik eingeführt wurde, werden in diesem Abschnitt sowohl der Stand der Forschung von HAR aus verschiedenen Anwendungsbereichen als auch die Limitationen dieses Ansatzes dargestellt. Eine im Rahmen dieser Arbeit durchgeführte systematische Literaturrecherche identifizierte 1243 Veröffentlichungen im Forschungsfeld der HAR, die über den zuvor dargestellten Stand der Technik hinaus vielfältige Potenziale der HAR zeigen [Rei+19a]. So wurde etwa der Anteil verschiedener Tätigkeiten während der Arbeitsausführung zur Prozessoptimierung herangezogen, etwa zur Reduktion von Laufwegen oder zur Minimierung von Wartezeiten in Kommissionier- und Lagerprozessen [BAF25; BAR21; Dön+23; Rei+18a].

Ein weiterer Anwendungsbereich ist die Erkennung arbeitsbezogener Bewegungsmuster, beispielsweise wiederholtes Bücken oder das Tragen schwerer Lasten, was eine Bewertung der ergonomischen Belastung über den Arbeitstag hinweg ermöglicht. Durch HAR lassen sich solche wiederkehrenden Aktivitäten identifizieren und in Warnsysteme integrieren, die Beschäftigte zu ergonomisch günstigen Verhaltensweisen anleiten. Weiterhin eignet sich die Aktivitätserkennung zur Dokumentation von Szenarien mit repetitiven Aufgaben, bei denen ein Aktivitätsprotokoll geführt wird, ohne personenbezogene Identitätsinformationen offenzulegen [Kac+22].

Für die Aktivitätserkennung lassen sich aus der Literatur sowohl klassische Verfahren des maschinellen Lernens [Dem+20] als auch moderne Deep Learning Architekturen [Shi+25] ableiten. Zu den klassischen Verfahren zählen unter anderem Random Forest (RF) [Fel+16], Quadratic Discriminant Analysis (QDA) [SR12], Hidden Markov Model (HMM) [LC11], k-Nearest Neighbor (k-NN) [ZO18], Support Vector Machine (SVM) [Ang+12] sowie XGBoost [ZZL19].

Zu den Deep Learning Ansätzen gehören beispielsweise Convolutional Neural Network (CNN) [CX15], Temporal Convolutional Neural Network (TCNN) [RC16], Long Short-Term Memory (LSTM) [ZCS19] und Transformerbasierte Modelle [RC16].

In der Praxis werden häufig hybride Ansätze eingesetzt, bei denen mehrere Modelle oder Architekturen kombiniert werden. Ein bekanntes Beispiel ist die Verknüpfung von CNN und LSTM [OR16]. Ferner existieren multimodale Ansätze, die unterschiedliche Sensortypen gemeinsam als Eingabedaten verwenden.

Die Autoren in [Che+13a; Che+13b; LNH14; Rei+18a; RF18; VNK15; Yag+20] heben die Bedeutung semantischer Attribute für HAR hervor, die Transferlernen unterstützen. Attributbasierte Aktivitätsklassifikation, die aus der Bildverarbeitung stammen, ermöglichen Zero Shot Lernen und Klassengeneralisierung, wobei Ansätze mit Unsicherheitssampling und evolutio-

nären Algorithmen eine Leistung erzielen, die mit klassenbasierten Methoden vergleichbar oder besser ist [Che+13a].

Definition: *Attribute*

Ein Klassenlabel wird als Attribut bezeichnet, wenn es zur semantischen Beschreibung oder Klassifikation einer übergeordneten Zielgröße (z. B. Aktivität, Prozess) verwendet wird. Attribute sind somit Klassenlabels, die nicht selbst Zielgröße des betrachteten Modells sind, sondern dessen Eingangsrepräsentation darstellen.

Folglich ist die Unterscheidung zwischen Aktivität und Attribut nicht im Label selbst begründet, sondern ergibt sich aus seiner funktionalen Rolle innerhalb der jeweiligen Klassifikationsaufgabe.

Schwerpunkte der Beiträge sind die Anwendung und der Vergleich von KI-Methoden, die Untersuchung der Sensorplatzierung und Sensorkonfiguration sowie die Erkennung von Klassenlabels in spezifischen Anwendungsbereichen. Die Industrie ist mit acht von 1243 Beiträgen ein unterrepräsentierter Bereich. Ziel der Beiträge ist die Verbesserung der Erkennungsleistung und die Ermöglichung einer immer granulareren Beschreibung von Bewegungen. Sie betrachten nur selten den Kontext, in dem eine Aktivität geschieht, beispielsweise wo oder unter welchen Bedingungen eine Aktivität ausgeführt wird. Kein Verfahren ermöglicht die Überführung von Aktivitäten und Kontextinformationen in übergeordnete Prozesse im Sinne von Ablaufabschnitten der REFA-Zeitstudie. Daher sind auf Grundlage des bisherigen Stands der Forschung weder eine detailliertere Analyse von Arbeitsabläufen noch ein automatisches Erkennen von Abweichungen gegenüber einem definierten Sollprozess möglich. Diese Einschränkung verdeutlicht die in Abschnitt 1 aufgezeigte Forschungslücke 1 *Prozesserkennung*.

3.2 Kontextinformationen im Rahmen der HAR

Eine im Rahmen dieser Arbeit durchgeführte systematische Literaturrecherche zum Thema Kontext in HAR zeigt, dass der Begriff Kontext nicht einheitlich definiert ist. Abgeleitet aus der Literaturrecherche gilt daher folgende Definition und Abgrenzung zur menschlichen Bewegung.

Definition: *Kontext und dessen Abgrenzung zur menschlichen Bewegung*

Dourish [Dou04] beschreibt Aktivitäten als Entitäten, die zwar in einen Kontext eingebettet, jedoch nicht zwingend von diesem abhängig sind, um zu existieren. Aufbauend auf diesem Verständnis wird in der vorliegenden Arbeit zwischen menschlichen Bewegungen als Grundlage der HAR (z. B. Gehen, Greifen, Sitzen, Beugen) und dem Kontext unterschieden, der für die Durchführung dieser Bewegungen nicht zwingend erforderlich ist, jedoch zusätzliche Informationen zur Interpretation und zum Verständnis der menschlichen Aktivität bereitstellt. Letzterer wird als menschlicher Kontext bezeichnet und unter dem Begriff Human Context Recognition (HCR) zusammengefasst.

Der Kontext umfasst dabei unterschiedliche Dimensionen, darunter Informationen über den räumlichen und zeitlichen Rahmen, den zugrunde liegenden Prozess, die Identität des Akteurs sowie die Bedingungen von Personen und deren physischer Umgebung [BAR21; SBG99]. Kontextinformationen stellen somit eine Ergänzung zur reinen Bewegungserkennung dar und ermöglichen eine semantisch reichhaltigere Interpretation menschlicher Aktivitäten, insbesondere in komplexen Arbeitsumgebungen wie der Intralogistik.

Kontextinformationen lassen sich in drei Kategorien unterteilen:

- **Sensordaten**, beispielsweise Lokalisierungs- oder Zustandsdaten
- **Klassenlabels**, d. h. diskrete, annotierbare Bezeichnungen
- **Wissensbasierte Informationen**, etwa strukturelles oder domänenspezifisches Wissen wie die Zusammensetzung eines Auftrags oder ein idealtypischer Prozessablauf.

HAR profitiert von der Integration kontextbezogener Informationen, indem es die Erkennungsleistung und Robustheit durch die Nutzung zusätzlicher Datenquellen verbessert, die Einblicke in die Umgebung oder die Aufgabenstruktur liefern. Beispielsweise wurden hochrangige Prozesszustände verwendet, um die Fähigkeit von HAR-Modellen zu verbessern, zwischen visuell oder kinematisch ähnlichen Aktivitäten zu unterscheiden, die in unterschiedlichen Kontexten auftreten [Lüd+21]. In ähnlicher Weise liefern Lokalisierungsdaten [BCD22; BCP20; Ses21] Informationen über die verwendeten Objekte und Audiodaten [Ses21] semantische Kontextinformationen, die die Ergebnisse der Aktivitätserkennung verfeinern und die Erkennungsleistung steigern. Im Gesundheitswesen werden kontextsensitive Systeme eingesetzt, um Umgebungszustände zu erfassen und Bewegungsabläufe sowie Zustände von Personen situativ zu interpretieren [Bat+21; GDR20].

Ansätze zur Detektion und Klassifikation von Objekten in der First-Person View (FPV) verbessern die Genauigkeit bei der Erkennung objektbezogener Aktivitäten [Die+17].

Prozesse werden in der HAR-Literatur nur selten explizit adressiert und stattdessen häufig unter Begriffen wie hochrangige oder komplexe Aktivitäten subsumiert. Rosen und Senkal [RS22] definieren *high-level activities* als Aktivitäten, „die mehrere ereignisbasierte Aktivitäten in einer nicht deterministischen Abfolge enthalten und über einen langen, stark variierenden Zeitraum stattfinden." Beispiele hierfür sind *Morning routine*, *Coffee time*, *Lunch*, *Cleanup* und *Relaxing*. Im untersuchten *Opportunity*-Datensatz [Opport12; Rog+10] weisen diese Aktivitäten eine Dauer von wenigen Sekunden bis zu mehr als acht Minuten auf [RS22, S. 5]. In der Studie wurden sie direkt auf Basis der Sensordaten klassifiziert.

Symbolische und hybride HAR-Methoden bieten eine zusätzliche Möglichkeit zur Einbeziehung des Kontexts. Sie stellen menschliche Aktivitäten und ihre Abhängigkeiten mithilfe symbolischer Strukturen wie Regeln, Graphen oder Ontologien dar. Einige Systeme modellieren etwa die kausale Struktur von Aktivitäten mit Vorbedingung-Wirkungs-Regeln. Das bedeutet, dass bestimmte Aktionen nur dann stattfinden, wenn bestimmte Objektzustände oder -lokalisierungen vorliegen [Krü+14; Rib+16; Rue+19]. Kontextinformationen lassen sich in das Beobachtungsmodell dieser Methoden integrieren, das Sensoreingaben mit Systemzuständen verknüpft.

Zwar in anderen HAR-Forschungsbereichen verbreitet, ist die Verwendung von Kontext in der Intralogistik weitgehend unerforscht. Insbesondere ist unklar, welche lagerspezifischen Kontextinformationen den größten Beitrag zur Steigerung der HAR-Leistung leisten, sowie wie wiederholende Prozessschritte erkannt werden.

3.3 Systematische Übersicht öffentlich zugänglicher HAR-Datensätze

Die folgende systematische Übersicht von HAR-Datensätzen offenbart die Grenzen ihrer Anwendbarkeit für die Evaluation der Prozesserkennung und liefert gleichzeitig Richtwerte für die Erstellung von HAR-Datensätzen im Allgemeinen. Die Datensatzrecherche ist eine Modifikation der Richtlinien für Literaturrecherchen, die von Kitchenham und Brereton [KB13; Kit+09; Kit04] und Chen et al. [Che+17] vorgeschlagen wurden.

Zunächst werden Datensätze anhand einer vordefinierten Liste von Schlüsselwörtern gesucht (siehe Schritt 1 in Abbildung 3.1). Anschließend wird die Liste der Datensätze nach Auswahlkriterien gefiltert (Schritt 2). Als dritter Schritt werden Datensätze aus Artikeln gewonnen, die Methoden für HAR vorstellen. Dieser Schritt umfasst eine Schleife. Im vierten Schritt werden Inhalt und Eigenschaften der Datensätze analysiert.

Von den insgesamt 201 untersuchten HAR-Datensätzen erfüllten 86 Datensätze alle vier nachfolgend definierten Auswahlkriterien. Für Datensätze mit Arbeitsbezug wurden die Auswahlkriterien jedoch mit reduzierter Restriktivität angewandt, d. h. einzelne Anforderungen galten in diesem Fall als erfüllt:

- **Mensch**: Daten beziehen sich auf menschliche Bewegungen.
- **Sensor**: Der Datensatz ist mit Arbeitsbezug oder enthält IMU- und/oder optisches Motion Capture (oMoCap)-Daten.
- **Zugang**: Der Datensatz ist mit Arbeitsbezug oder ist online zugänglich, herunterladbar und kostenlos.
- **Körperliche Aktivität**: Definition siehe Abschnitt 2.2.4

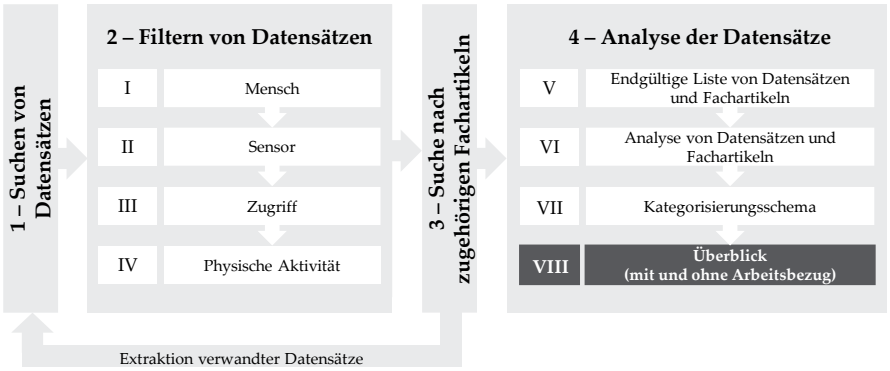


Abb. 3.1 Methode der Datensatzrecherche

Seit 2009 ist ein deutlicher Anstieg der veröffentlichten Datensätze zu verzeichnen (siehe Abbildung 3.2). Bei der Filterung wurden keine zeitlichen Einschränkungen berücksichtigt. Allerdings konnten keine Datensätze vor 2003 und für den Zeitraum 2003 bis 2008 vier Datensätze gefunden werden. Die 86 recherchierten Datensätze werden in den folgenden beiden Abschnitten in HAR-Datensätze ohne (64) und mit Arbeitsbezug (22) unterteilt.

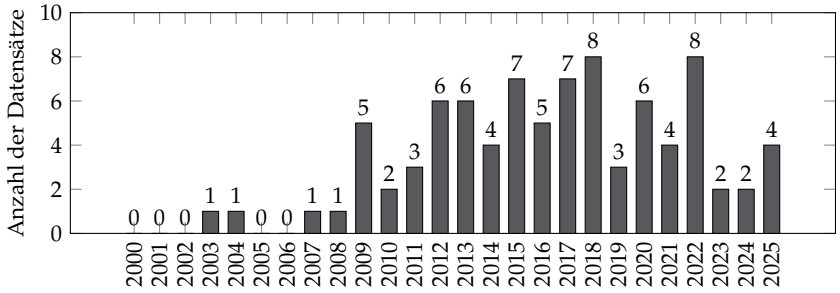


Abb. 3.2 Anzahl von HAR-Datensätzen nach Erscheinungsjahr

3.3.1 HAR-Datensätze ohne Arbeitsbezug

Die 64 Datensätze ohne Arbeitsbezug sind nach den Kategorien *Allgemeine Informationen*, *Labelkategorie*, *Datenspezifikation* und *Sensor* gegliedert und nach Erscheinungsjahr absteigend sortiert (siehe Tabelle 3.1). Sie liefern grobe Richtwerte für typische Spezifikationen eines HAR-Datensatzes, die sich auf intralogistische Datensätze übertragen lassen.

Allgemeine Informationen

Die Datensätze wurden sowohl auf Repositorien (z. B. Figshare, Kaggle, UCI Machine Learning Repository, Mendeley Data, Zenodo) als auch auf Plattformen veröffentlicht, die die Kriterien eines Repositoriums nicht erfüllen, etwa universitäre Webseiten, Dropbox oder Google Drive. Dadurch waren 19 Datensätze zum Zeitpunkt der Recherche nicht mehr verfügbar und wurden in der dritten Phase des Filterungsprozesses aussortiert.

Die meisten öffentlich zugänglichen HAR-Datensätze adressieren drei Anwendungsbereiche: Gesundheitswesen, Sport sowie Smart Homes bzw. Ambient Assisted Living (AAL) [Al +25]. Sie umfassen überwiegend Klassenlabels wie Activities of Daily Living (ADL), Fortbewegung, Gesten, Sportaktivitäten und Sturzerkennung [Pab+25]. Andere Bereiche wie Unterhaltung, Psychologie, Robotik oder Überwachung sind dagegen unterrepräsentiert.

Klassenlabels

Begriffe wie *Aktivität*, *Aktivitätsklasse* oder *Klassenlabel* werden uneinheitlich verwendet. *Aktivität* bedeutet entweder Bewegung, Handlung oder Prozessschritt; teilweise werden auch Tanzbewegungen oder Gesten darunter gefasst. Nur wenige Arbeiten definieren eine Hierarchie von Aktivitäten und beschreibenden Merkmalen (z. B. Körperhaltungen oder Attribute). Im *UTD Multimodal Human Action Dataset* [CJK15a] wurde etwa dieselbe Bewegung der linken und rechten Hand als individuelles Klassenlabel annotiert.

Die Anzahl der Klassenlabels variiert stark in Abhängigkeit von der Anzahl und den Eigenschaften seiner Anwendungsbereiche. Beispielsweise befasste sich [Che+18a] ausschließlich mit Fortbewegungsaktivitäten, die in *langsam gehen* und *laufen* unterteilt sind. Im Gegensatz dazu enthält der *[HDM05]*-Datensatz 70 Aktivitätsklassen in den Bereichen Sportaktivitäten, Fortbewegung, ADL und Tanz.

Auch die Dauer der annotierten Klassenlabels variiert stark: von Sekundenbruchteilen bis zu 60 Minuten [Kas+17], während sie im *PAMAP2*-Datensatz etwa 3 Minuten beträgt [Rei12].

Datenspezifikation

Die Aufnahmedauer schwankt von 15 Minuten (*BodyAttack Fitness* [BodyA09]) bis 7.140 Minuten (*Self-Annotated Wearable Activity Data* [HV24a]).

Im Mittel umfasst ein Datensatz 865,84 Minuten. 39 Datensätze enthalten höchstens 15 Probanden, der Durchschnitt liegt bei 20 Probanden.

In mehreren der untersuchten Datensätze führten die Probanden zur Vereinfachung der Annotation jeweils nur eine Aktivität aus, wodurch jedoch natürliche Bewegungen und Aktivitätsabfolgen nur eingeschränkt erfasst wurden [Man+15; UIPRMD17]. Bei längeren Erhebungen über mehrere Tage wurden pro Proband Aufnahmen von 2 bis 6 Tagen durchgeführt [SS16], wodurch realitätsnahe menschliche Aktivitäten abgebildet wurden.

Sensor

IMU-Sensoren dominieren mit 52 Datensätzen, vorwiegend aufgrund geringer Kosten, Robustheit und Einsatzfähigkeit in verschiedenen realen Umgebungen. Die Abtastraten, welche von 10 bis 256 Hz reichen, werden häufig ohne Begründung gewählt. Smartphones wurden besonders häufig als IMU eingesetzt. In [DailyLog16] trug jeder Proband sechs Smartphones am Körper verteilt. Vereinzelt kamen Smartwatches und Smartbrillen als IMU zum Einsatz. Die Sensorpositionen variieren stark (z. B. Tasche, Hand oder Gürtel).

oMoCap-Systeme sind kostenintensiver und infrastrukturell aufwändiger als IMU. Insgesamt enthalten 17 Datensätze oMoCap-Daten, vier davon kombiniert mit IMU. oMoCap-Systeme liefern präzise Referenzdaten [MADS17; TotalCap17], erfassen jedoch nur gemarkerte Entitäten. Als Folge sind Bewegungen zunehmend schwerer zu labeln, je weniger kontextuelle Informationen vorliegen. Wegen dieser Limitation werden oft zusätzlich RGB-Videos zur Annotation aufgezeichnet [Mau+19a; Nie+20c; RP13].

Vorgehen bei der Datensatzerstellung

Beschreibungen zum Erstellungsprozess fehlen meist oder bleiben rudimentär. Ein standardisierter Annotationsablauf ist kaum ableitbar; Angaben zum Annotationstool wie in [Mau+19a] sowie die Veröffentlichung von Richtlinien oder Tools wie in [KIT10] sind Ausnahmefälle. Die Annotationen wurden sowohl von Laien als auch von Experten durchgeführt. In *Daphnet Gait* wurde das Gangbild von Parkinson Patienten von einem Physiotherapeuten analysiert [RP13]. Neben dem Fachwissen unterscheidet sich auch die Anzahl der Annotatoren. Der *Hand Gesture*-Datensatz [HandG13] wurde von einer Person annotiert, während *AndyData-lab-onePerson* [Mau+19a] drei Annotatoren umfasste. Der Aufwand für die Annotation variiert stark. Einige Daten wurden in Echtzeit und teilweise während der Datenaufnahme annotiert [RealWorld16; Rei12; RP13; SIPI12]. Daten wie [Opport12] erforderten 14 bis 20 Minuten für die Annotation einer einminütigen Aufnahme.

Tabelle 3.1 Systematische Übersicht von HAR-Datensätzen ohne Arbeitsbezug. Die Einträge sind chronologisch in absteigender Reihenfolge nach Erscheinungsjahr und alphabetisch nach dem Namen des Datensatzes sortiert.

Allgemeine Informationen				Labelkategorie						Datenspezifikation								Sensor	
Jahr	Datensatz Name	Ref. [Datensatz]	Ref. [Artikel]	Sportak.	Fortbewegung	ATL	Sturzerkennung	Handgesten	Tanz	Umfang [min]	Datengröße [MiB]	Format	Anzahl Probanden	Anzahl Label	Labor	reales Leben	oMoCap [fps]	IMU [Hz]	Andere Sensoren
2025	Daily Activities Wearable Dataset for Cardiorespiratory Fitness Estimation	[Sal+25b]	[Sal+25a]	x	x	x				2220	404,07	csv	60	6	x		50	50	
2025	eegMobility	[Coo+25]	[Nil25]		x	x				1380	895,57	datx, csv	1	9		x		256	Zmax EEG
2025	RecGym	[Bia+25]	[BL25]	x						3000	98,51		10	12		x		20	Körperkapazitätssen.
2024	BandX-Activity	[Sah+24]	[SS24]	x	x					-	1,33	csv	33	7		x		20	
2024	Self-Annotated Wearable Activity Data	[HV24a]	[HV24b]	x	x	x	x			7140	1335,14	csv	11	22	x		25		
2023	Hang-Time HAR	[Hoe+23b]	[Hoe+23a]	x	x					186	96,13	csv, txt	24	13		x	60	50	Handgelenkssen.
2022	Flaap	[KS22a]	[KS22b]	x	x	x				246,93	2012,25	csv	8	10	x			100	
2021	KU-HAR	[SN21]	[NSR21]	x	x	x				802	1211,16	csv	90	18	x			100	
2020	Bath Natural Environment HAR Data Set	[SPI21]	[She21]	x	x	x				268	649,74	csv	22	6		x		100	
2020	w-HAR	[Bha+20]	-	x	x	x				180		csv	22	7	x			250	Dehnungssensor
2019	Human Activity Recognition from Continuous Ambient Sensor Data	[AK22]	[CCT19]			x				-	12.397,8	csv	-	8		x		125	
2018	Fall-UP Dataset (Human Activity Recognition)	[FALLUP18]	[Mar+19]		x	x	x			165,00	78	csv	17	11	x			100	infrarot, RGB
2018	First-Person View	[FPV18]	-		x	x				-	1046,86	mp4, csv	2	7		x		x	RGB
2018	HuGaDB	[HuGaDB18]	[CK18]		x					600	401	txt	18	12		x		x	EMG
2018	Oxford Inertial Odometry Dataset (OxIOD)	[Che+18a]	[Che+18b]		x					883,2	2751,73	csv	4	2	x	x	250	100	
2018	Simulated Falls and Daily Living Activities Data Set	[ZB14]	[ÖB14]		x	x	x			630	3972,06	txt	17	36	x			25	
2018	UMONS-TAICHI	[TAICHI18]	[Tit+18]	x						-	28.242,47	txt, c3d, tsv	12	13	x		179		RGB, Tiefe
2017	An Open Dataset for Human Activity Analysis using Smart Devices	[Open17]	[Fay+17]	x	x	x				-	433	csv	1	16		x		x	
2017	IMU Dataset for Motion and Device Mode Classification	[IPIN17]	[Kas+17]		x					-	2835,21	mat	8	3		x		100	
2017	Martial Arts, Dancing and Sports (MADS) Dataset	[MADS17]	[Zha+17]	x					x	-	24.234,96	mov, zip	5	5	x		60		RGB
2017	Physical Rehabilitation Movements Data Set (UI-PRMD)	[UIPRMD17]	[Vak+18]	x	x					-	4700,17	txt	10	10	x		100		Tiefe
2017	SisFall	[SisFall17]	[SLV17]		x	x	x			1849,33	1627,67	txt	38	34		x		200	
2017	TotalCapture Dataset	[TotalCap17]	[Tru+17]	x	x					-	-	-	5	5	x			60	RGB
2017	UniMiB SHAR	[UniMiB17]	[MMN17]		x	x	x			-	255	mat	30	17	x			50	Mikrofon
2016	Daily Log	[DailyLog16]	[Szt+16]	x	x	x				106,56	4815,97	csv	7	33		x		x	GPS
2016	HDM12 Dance	[HDM12]	[VK16]						x	97	2.175,48	asf, c3d	22	20	x		128		

Tabellenfortsetzung

Generelle Informationen				Labelkategorie						Datenspezifikation								Sensor	
Jahr	Datensatz Name	Ref. [Datensatz]	Ref. [Artikel]	Sportakt.	Fortbewegung	ATL	Sturzerkennung	Handgesten	Tanz	Aufnahmezeit [min]	Datengröße [MiB]	Format	Anzahl Probanden	Anzahl Label	Labor	Reales Leben	oMoCap [fps/Hz]	IMU [Hz]	Andere Sensoren
2016	RealWorld	[RealWorld16]	[SS16]		x	x				1065	3891,92	csv	15	8		x		50	GPS, Magnetfeld, RGB, Mikrofon, Licht
2016	UMAFall: Fall Detection Dataset	[CA18]	[CSC17]		x	x	x			-	359	csv	19	14		x		200	
2015	Complex Human Activities Dataset	[CHAD15]	[Sho+16]		x	x				390	240	csv	10	13		x		50	
2015	Heterogeneity Activity Recognition Data Set (HHAR)	[BB15]	[Sti+15]		x					270	3333,73	csv	9	6		x		200	
2015	HuMoD Database	[HuMoD15]	[WV15]	x	x					49,4	6044,27	mat	2	8	x		500		EMG
2015	Project Gravity	[Gravity15]	[Vil+15]		x	x	x			-	4583,5	json	3	19	x			25	RGB
2015	Smartphone-Based Recognition of Human Activities and Postural Transitions Data Set (SBHAR)	[Rey+15]	[Rey+16]		x	x				300	240	txt	30	12		x		50	RGB
2015	UTD Multimodal Human Action Dataset (UTD-MHAD)	[CJK15a]	[CJK15b]	x	x			x		-	1316,15	mat, avi	8	27	x			50	Tiefe
2014	Activity Recognition from Single Chest-Mounted Accelerometer Data Set	[CP14]	[CPR12]		x	x				431	44,2	csv	15	7		x		52	
2014	Realistic sensor displacement benchmark dataset (REALDISP)	[BTA12]	[Ban+14a]	x	x					566,02	6717,43	txt	17	33	x			50	
2014	Sensors activity dataset	[SAD14]	[Sho+14]		x					2800	308	csv	10	8		x		50	
2014	User Identification From Walking Activity Data Set	[Cas14]	[CPR12]		x	x				431	4319,1	csv	22	5		x		52	RGB, Mikrofon
2013	Actitracker (WISDM)	[WISDM13]	[Loc+11]		x	x				-	2588,92	txt	29	6		x		20	
2013	Daily and Sports Activities Data Set	[BA10]	[BY14]	x	x	x				760	402	csv	8	19		x		25	
2013	Daphnet Freezing of Gait Data Set	[RP13]	[Bac+10]		x					500	86,2	txt	10	3	x			64	RGB
2013	Hand Gesture	[HandG13]	[BBS14]			x		x		70	47,6	mat	2	11		x		32	
2013	Physical Activity Recognition Dataset Using Smartphone Sensors	[PARDUSS13]	[SSH13]		x					-	63,1	xlsx	4	6		x		50	
2013	Wearable Computing: Accelerometers' Data Classification of Body Postures and Movements (PUC-Rio)	[UC13]	[Ugu+12]		x					480	4582,1	dat	4	5	x			10	
2012	Activity Prediction (WISDM)	[WISDM12]	[KWM11]		x					-	49,1	txt	29	6	x			20	
2012	HDM12 Dance	[HDM12]	[VK16]						x	97,48	585,63	rar	22	21	x		128		
2012	Human Activity Recognition Using Smartphones Data Set (UCI HAR)	[Rey+13]	[Ang+13]		x	x				192	269	txt	30	6	x			50	
2012	OPPORTUNITY Activity Recognition Data Set	[Opport12]	[Rog+10]		x	x		x		1500	859	txt	12	24		x		32	
2012	PAMAP2 Physical Activity Monitoring Data Set	[Rei12]	[RS12]	x	x	x				600	1652,47	txt	9	18	x	x		100	Herzfrequenzmesser
2012	USC-SIPI Human Activity Dataset	[SIPI12]	[ZS12]		x					-	42,7	mat	14	12		x		100	

Tabellenfortsetzung

Generelle Informationen				Labelkategorie						Datenspezifikation							Sensor	
Jahr	Datensatz Name	Ref. [Datensatz]	Ref. [Artikel]	Sportakt.	Fortbewegung	ATL	Sturzerkennung	Handgesten	Tanz	Aufnahmezeit [min]	Datengröße [MiB]	Format	Anzahl Probanden	Anzahl Label	Labor	Reales Leben	oMoCap [fps/Hz]	IMU [Hz]	Andere Sensoren
2011	3DLife/Huawei ACM MM Grand Challenge 2011	[3DLife11]	[Ess+12]						x	-	-	svl, cvs	15	5	x			160	RGB, Mikrofon, Tiefe
2011	UCF-iPhone Data Set	[UCF11]	[MRS12]	x	x					-	4567,0	csv	9	9		x		60	
2011	Vicon Physical Action Data Set	[The11]	[TH07]		x	x				33,33	144	txt	10	20	x		200		
2010	KIT Whole-Body Human Motion Database	[KIT10]	[Man+15]	x	x	x		x	x	-	2.097,152	xml, c3d, avi	224	43	x		100		RGB
2010	Localization Data for Person Activity Data Set	[Vid+10]	[Kal+10]		x	x	x			-	4579,7	txt	5	11	x			10	
2009	BodyAttack Fitness	[BodyA09]	[FRT09]	x						15	2349,8	mat	1	6	x			64	
2009	Carnegie Mellon University Multimodal Activity (CMU-MMAC) Database	[Kitch09]	[SDH09]			x				-	60.897,03	amc, txt, asf, wav, xls, avi	43	29	x		120	125	RGB, Mikrofon, RFID, BodyMedia
2009	HCI gestures	[BodyA09]	[FRT09]					x		-	4591,2	mat	1	5	x			96	
2009	HumanEva I	[EvaI09]	[SBB10]	x	x					-	13.824	-	4	6	x			120	RGB, depth
2009	HumanEva II	[EvaII09]	[SBB10]		x					-	4.649	-	2	4	x			120	RGB
2008	Wearable Action Recognition Database (WARD)	[WARD08]	[Yan+08]		x	x				-	41,66	mat	20	13		x		20	
2007	HDM05	[HDM05]	[Mül+07]	x	x	x			x	-	3000,32	c3d, amc, avi	5	70	x		120		RGB
2004	Leuven Action Database	[ActionData04]	[VV04]	x	x	x				-	14	text, avi, xls, pdf	1	22	x		30		RGB
2003	Carnegie Mellon University Motion Capture Database (CMU Mocap)	[CMU23]	-	x	x	x			x	-	18.673	amc	112	23	x		120		
Anz.	**64**			**27**	**53**	**36**	**8**	**5**	**7**						**36**	**30**	**17**	**52**	
Min.										**15**	**1,33**		**1**	**2**			**25**	**10**	
$\bar{x}$										**865,84**	**4241,38**		**20,03**	**14,14**			**135,63**	**79,44**	
Max.										**7.140**	**60.897**		**224**	**70**			**500**	**256**	

Anmerkung: x = zutreffend, - = keine Angaben vorhanden, EMG = Elektromyografie, GPS = Global Positioning System, PPG = Photoplethysmogramm, RFID = Radiofrequenz-Identifikation.

Insgesamt existieren weder eine einheitliche Struktur zur Dokumentation noch ein konsistentes Vokabular. Begriffe wie *Aktivitätsklasse* und *Klassenlabel* werden unterschiedlich interpretiert, und die fehlende langfristige Verfügbarkeit mancher Datensätze unterstreicht das Fehlen etablierter Standards bei der Erstellung und Veröffentlichung von HAR-Datensätzen.

3.3.2 HAR-Datensätze mit Arbeitsbezug

Bis 2015 war der Anwendungsbereich *Arbeit* nicht vertreten. Erst mit dem *Skoda Mini Checkpoint*-Datensatz [Skoda15; Zap+08] rückte die *Arbeit* verstärkt in den Fokus der HAR. In der Folge wurden zwischen 2015 und 2025 insgesamt 22 Datensätze zu diesem Anwendungsbereich veröffentlicht.

Die Tabelle 3.2 verweist auf die Datensätze und deren Referenzarbeit. Aufgeführt sind das Veröffentlichungsjahr, die öffentliche Verfügbarkeit, die Anzahl und der Typ der eingesetzten Sensorik sowie die Charakteristiken der Aufnahmeumgebung und Annotation. Die Sensorik umfasst visuelle Systeme (z. B. oMoCap, RGB, RGB-D) und nichtvisuelle Sensoren (z. B. Trägheits-, Bio- und taktile Sensoren). Die Sensoranzahl bezieht sich auf am Menschen oder in der Umgebung installierte Geräte; bei oMoCap entspricht sie der Anzahl der verwendeten Kameras. Unterschieden werden reale, semi-kontrollierte und kontrollierte Labor- sowie virtuelle Aufnahmeumgebungen. Die Label- und Annotationsangaben beschreiben Zielkategorie (z. B. Körperhaltung, Mensch-Objekt- oder Mensch-Roboter-Interaktion), Granularität sowie die Annotationsmethode (Experten, manuell, automatisch, Selbstannotation oder protokollierte Durchführung). Ein Sonderfall ist der *InHARD-DT*-Datensatz [Dal+23], bei dem Bewegungen während der Interaktion mit einer Virtual-Reality-Szene aufgezeichnet wurden.

Die Tabelle verdeutlicht eine Verschiebung des Forschungsschwerpunkts: Während frühe Datensätze primär menschliche Körperhaltungen im industriellen Kontext betrachteten [Ben+24], nehmen Mensch-Objekt- und insbesondere Mensch-Roboter-Interaktionen deutlich zu. Die Datensätze unterscheiden sich erheblich hinsichtlich Sensorkonfiguration, Probandenzahl, Bewegungsrepräsentation und Klassendefinition; lediglich vier Datensätze wurden in realen Umgebungen aufgezeichnet.

Trotz der industriellen Ausrichtung decken die Datensätze das Spektrum industrieller Bewegungen nur partiell ab. Bewegungsmuster variieren stark zwischen Tätigkeiten wie Verpacken, Kommissionieren oder Montage. Einige Datensätze (z. B. *IKEA ASM* [Ben+21; IKEA20] und *Skoda Mini Checkpoint* [Zap+08]) fokussieren Montageprozesse, während *Physical Human Robot Contact Detection* [Mar21; Moh+20] und *COVERED* [Ami22; Mun+22] Mensch-Roboter-Interaktionen adressieren. Logistikszenarien werden durch *AndyData-lab-onePerson* [Mau+19a], *OpenPack* [Yos+24] und *Logistic Activity Recognition Challenge (LARa)* [Nie+20a] repräsentiert.

Tabelle 3.2 Systematische Übersicht von HAR-Datensätzen mit Arbeitsbezug

Datensatz				Sensoren		Sub.	Aufnahme	Label		Annotation
Name	Ref.	Jahr	Ver.	Nr.	Art	Nr.	Umgebung	Kategorie	Nr. und Art	
MPP Datensatz	[For+25; Worker25]	2025	x	2	Trägheits-	4	reale Welt	Mensch-Objekt-Interaktion	7 Aktivitätsklassen	Experte
IHAD$_v$ 1	[Stu+23]	2023	-	1	visuell (RGB)	-	kontrolliert	Mensch-Objekt-Interaktion	12 Aktivitätsklassen	
HRI30	[IDA22a; IDA22b]	2022	x	1	visuell	11	kontrolliert	Körperhaltung, Mensch-Objekt-Interaktion und Mensch-Roboter-Interaktion	30 Aktions	manuelle Annotation
CoAx	[CoAx21; Lag+22]	2022	x	1	visuell (RGB-D)	6	kontrolliert	Mensch-Objekt-Interaktion und Mensch-Roboter-Interaktion	10 Aktionen und 8 Objektanmerkungen	Aktions- und Objektannotation
OpenPack	[OpenPack22; Yos+24]	2022	x	20	visuell, Trägheits-, physiologische/Biosensoren, sonstige	16	kontrolliert	Mensch-Objekt-Interaktion	11 Aktionsklassen	Experte
InHARD-DT	[Dal+23; InHARDDT22]	2022	x	34	visuell (RGB, oMoCap), Trägheits-	12	virtuell	Mensch-Objekt-Interaktion und Mensch-Roboter-Interaktion	18 Event-/ Aktionsklassen	automatisch beschriftet
HA4M	[Cic+22; Mar+22]	2022	x	1	visuell (RGB, RGB-D, Infrarot)	41	kontrolliert	Mensch-Objekt-Interaktion	12 Aktionen	manuelle Annotation
Assembly101	[assembly22; Sen+22]	2022	x	13	visuell	53	kontrolliert	Mensch-Objekt-Interaktion	1380 feinkörnig, 202 grobe Aktionen	geschulte Annotatoren
COVERED	[Ami22; Mun+22]	2022	x	1	visuell	-	reale Welt	Körperhaltungen, Mensch-Roboter-Interaktion	6 semantische Segmentierungsklassen	
WGD	[Tam+21]	2021	-	8	visuell (oMoCap, RGB)	8	kontrolliert	Körperhaltung, Mensch-Objekt-Interaktion	-	-
Physical Human Robot Contact Detection	[Mar21; Moh+20]	2021	x	2	visuell (RGB-D)	-	kontrolliert	Mensch-Roboter-Interaktion, Körperhaltungen	5 Aktionen	-
ABC Bento	[Ali+21; Bento21]	2021	x	20	visuell (oMoCap)	4	kontrolliert	Mensch-Objekt-Interaktion	10 Labels	Teilnehmer entwickeln Methoden

Tabellenfortsetzung

Datensatz					Sensoren	Sub.	Aufnahme	Label		Annotation
Name	Ref.	Jahr	Ver.	Nr.	Art	Nr.	Umgebung	Kategorie	Nr. und Art	
InHARD	[Dal+20a; Dal+20b]	2020	x	35	visuell (oMoCap, RGB)	16	semi-kontr.	Mensch-Objekt-Interaktion	14 low-level, 74 high-level Aktivitätsklassen	Annotationstool Anvil
LARa	[Nie+20a; Nie+20c; Nie+22b; Nie+23]	2020	x	54	visuell (RGB, oMoCap), Trägheits-	16	kontrolliert	Körperhaltungen/statische Aktivitäten, Mensch-Objekt-Interaktion, Fortbewegung	8 Aktivitätsklassen, 19 Attribute	Annotationstool SARA
MECCANO	[Rag+21; RFF20]	2020	x	1	visuell	20	kontrolliert	Mensch-Objekt-Interaktion	61 Aktionsklassen mit Verb und Objekten und Begrenzungsrahmen Anmerkungen	manuelle Annotation
IKEA ASM	[Ben+21; IKEA20]	2020	x	3	visuell (RGB, RGB-D)	48	kontrolliert	Mensch-Objekt-Interaktion	33 Verb-Objekt	Amazon Turk, manuell
AndyData-lab-onePerson	[Mau+19a; Mau+19b]	2019	x	31	visuell (oMoCap, RGB), Trägheits-, taktil/Kraft-	13	kontrolliert	Körperhaltungen/statische Aktivitäten, Mensch-Objekt-Interaktion	6 generell, 5 detaillierte Körperhaltung, 8 Aktion	Annotationstool Anvil
PPG-DaLiA	[Rei+19b; RI19]	2019	x	2	Trägheits-, physiologische/Biosensoren	15	semi-kontr.	Körperhaltungen/statische Aktivitäten, ATL, Sport	9 Aktivitätslabels	protokolldefiniert
HAD-AW	[AEG18; MG18]	2018	x	1	Trägheits-	16	reale Welt	ATL, Sport	8 ATLs bestehend aus 31 Bewegungsprimitiven	
Nath et al.	[NCB18]	2018	-	2	Trägheits-	2	semi-kontr., reale Welt	Mensch-Objekt-Interaktion	5 Aktivitätslabels	manuelle Annotation
ExtraSensory Dataset	[ExtraSens16; VEL17]	2016	x	1	Trägheits-, Lokalisierungs-, Akustik-, Umgebungs-, Sonstige (Telefonstatus)	60	reale Welt	ATL	116 originale Labels, 51 Bereinigte Labels	durch den Nutzer
Skoda Mini Checkpoint	[Skoda15; Zap+08]	2015	x	20	Trägheits-	1	kontrolliert	Mensch-Objekt-Interaktion	10 Gesten, 70 Instanzen jeder Geste	Forscher

Anmerkung: x = zutreffend, - = nicht zutreffend, Sub. = Subjekte, Ver. = öffentliche Verfügbarkeit

Die Datensätze *LARa* und *OpenPack* unterscheiden sich zwar hinsichtlich der Sensorik und der Labelstruktur, weisen jedoch zugleich auch Gemeinsamkeiten auf. *LARa* basiert primär auf oMoCap- und IMU-Sensoren und verwendet eine kombinierte Aktivitätsklassen- und Attributannotation (z. B. Aktivitätsklasse *Stehen* mit Attributen wie Bewegungsgrad, Handnutzung oder Objektgröße). *OpenPack* integriert hingegen IMU-, Blutvolumenpuls-, elektrodermale Aktivitäts-, LiDAR- und Tiefensensoren. Wie bei *LARa* wurden die Bewegungen in *OpenPack* auf mehreren Ebenen annotiert. Ein *Vorgang* umfasst dabei eine oder mehrere *Aktionen*. Im Gegensatz zu *LARa* bleiben Übergangsphasen zwischen Aktionen teilweise ungelabelt.

Keiner der betrachteten Datensätze enthält kontextbezogene Sensordaten oder Labels. Die meisten Arbeiten beschränken sich auf Aktivitätsklassen; semantische Abläufe oder Prozessstrukturen werden selten modelliert. Lager- oder Produktionsprozesse liegen nicht als Annotation vor, und die korrekte Reihenfolge von Prozessschritten ist häufig unerheblich [Nie+20c], da die Bewegungscharakteristik selbst im Fokus steht. Entsprechend eignen sich diese Datensätze nicht für die Prozesserkennung. Dies unterstreicht die in Abschnitt 1 aufgezeigte Forschungslücke 2 *Datensatz*.

3.4 Methoden der Datensatzerstellung für HAR

Frameworks für die Erstellung von HAR-Datensätzen haben in der wissenschaftlichen Literatur bisher wenig Beachtung gefunden. Bestehende Übersichtsarbeiten, Umfragen und verwandte Beiträge konzentrieren sich überwiegend auf KI-Methoden und in gewissem Umfang auf die Zusammenfassung bestehender Datensätze. Die systematische Datensatzrecherche im vorherigen Kapitel sowie die systematischen Literaturrecherchen zu HAR und HCR zeigen, dass sich keine der identifizierten Arbeiten zur Datensatzerstellung auf ein strukturiertes Vorgehensmodell stützt. Einige Arbeiten schlagen allgemeine konzeptionelle Modelle innerhalb des HAR-Bereichs vor, wie z. B. *Frameworks* [KRK24; KSG18], *Pipelines* [Hua+24], *Chains* [Boc+21], *Prozesse* [HSZ19], *Taxonomien* [ABG22; Dem+23; Zha+22], *Methoden* [Reh+24], *Architektur* [SAG25] oder *Workflows* [Agu+19]. Diese Beiträge konzentrieren sich jedoch in erster Linie auf die Modellentwicklung, d. h. die Phasen nach der Datensatzerstellung. Stattdessen werden einzelne Aspekte der Datensatzerstellung, insbesondere Annotationsverfahren [Dem+23] thematisiert.

Über HAR hinaus wird die Bedeutung der Verbesserung der Datensatzqualität im maschinellen Lernen zunehmend anerkannt. Auf der Grundlage von Interviews mit 18 führenden Datensatzerstellern werden in [OC24] sieben Empfehlungen zur Verbesserung der Datensatzerstellung vorgeschlagen:

1. "Diversify your dataset and audit thoroughly
2. Strive for higher dataset quality
3. Start early and iterate

4. Document datasets openly and communicate limitations
5. Create user-centric datasets and limit inappropriate applications
6. Contend with privacy and consent
7. Make the datasets you need"

Das Fehlen standardisierter Verfahren zur Erstellung von Datensätzen und die allgemeine Knappheit hochwertiger Daten spiegeln sich deutlich in den in der Literatur identifizierten Herausforderungen und Einschränkungen wider. So stehen beispielsweise vier der fünf in [ABG22] aufgeführten Herausforderungen in direktem Zusammenhang mit der Erstellung von Datensätzen, angefangen von der Datenaufnahme und -vorverarbeitung bis zu Hardwareüberlegungen und Inkonsistenzen bei der Annotation. Viele bestehende HAR-Datensätze weisen Mängel auf, wie

- unvollständige oder fehlende Klassenlabels,
- nicht synchronisierte Sensordaten,
- Annotationen asynchron zu Sensordaten,
- begrenzte oder fehlende Metadaten,
- inkonsistente oder undokumentierte Klassenlabels und
- eingeschränkte Zugänglichkeit.

Eine geringe, durch fehlende Standardisierung bedingte Annotationsqualität beeinträchtigt die Genauigkeit von HAR-Modellen erheblich. Zudem identifizieren [KRK24] und [Zha+22] den Mangel an großangelegten, hochwertigen und gelabelten Datensätzen als zentrale Herausforderung.

Da für HAR kein Framework für die Datensatzerstellung vorhanden ist, wurde die Suche in anderen Domänen ausgeweitet, welche Forschungen am oder mit Menschen durchführen. In der Medizin liegen institutsspezifische Checklisten für Humanstudien vor. Diese Checklisten enthalten kritische Punkte, die Datenerheber bei der Erstellung von Datenerfassungsprotokollen zu berücksichtigen haben [ECM20]. In einigen Fällen werden solche Checklisten von institutionellen Ethikkommissionen herausgegeben und konzentrieren sich in erster Linie auf die Arten von Daten, deren Erfassung zulässig ist, sowie auf die Richtlinien zur Datenaufbewahrung [Beh+24; BOKU25]. Weiterhin stellen diese Checklisten sicher, dass alle ethischen Anforderungen während des gesamten Prozesses der Datenerstellung, -analyse und -speicherung berücksichtigt werden. In der Regel enthalten sie jedoch keine Leitlinien für den Prozess der Datensatzerstellung selbst.

Das Fehlen standardisierter Verfahren zur Datensatzerstellung sowie die identifizierten Verbesserungspotenziale bestätigen die in Abschnitt 1 aufgezeigte Forschungslücke 3 *Datensatzerstellung*. Die in der Medizin eingesetzten Checklisten zeigen jedoch, dass strukturierte Hilfsmittel dazu beitragen, wesentliche Anforderungen systematisch zu berücksichtigen. Die Übertragung dieses Grundgedankens auf die Datensatzerstellung für HAR stellt einen möglichen Ansatz zur Entwicklung standardisierter Vorgehensweisen dar.

Kapitel 4
Methodik

Zusammenfassung Das vierte Kapitel entwickelt die methodische Grundlage für die Datensatzerstellung und die spätere Prozesserkennung. Eine explorative Studie (CAARL) zeigt, dass Aktivitäten in intralogistischen Arbeitsabläufen eng mit Kontextinformationen, insbesondere Lokalisierungsdaten, verknüpft sind. Die Ergänzung von Bewegungsdaten um räumliche Kontextinformationen erhöht nicht nur die Erkennungsleistung, sondern verleiht den Aktivitäten eine inhaltliche Bedeutung im Arbeitsablauf. Aktivitäten lassen sich dadurch konkreten Handlungsschritten (z. B. Handhaben am Regal) zuordnen, statt lediglich als isolierte Bewegungen vorzuliegen. Die explorative Studie stellt damit einen ersten Schritt dar, Aktivitätsdaten vergleichbar zu manuellen Verfahren der arbeitswissenschaftlichen Zeitdatenerfassung auszuwerten. Aus diesen Beobachtungen folgt, dass sich Arbeitsprozesse aus der Kombination von Aktivitäts- und Kontextinformationen rekonstruieren lassen. Daraus ergibt sich die Anforderung an eine systematische Erfassung solcher Informationen, wofür ein Framework zur strukturierten Erstellung eines geeigneten Datensatzes entwickelt wird.

Dieses Kapitel basiert teilweise auf den folgenden Veröffentlichungen:

Friedrich Niemann u. a. „Context-Aware Human Activity Recognition in Industrial Processes“. In: *Sensors* (2021). DOI: 10.3390/s22010134

Friedrich Niemann u. a. *Context-Aware Activity Recognition in Logistics (CAARL) – A optical marker-based Motion Capture Dataset*. 2021. DOI: 10.5281/ZENODO.5680951

Fernando Moya Rueda u. a. „Activity- and Context-Sensitive Recognition of Human-Centered Processes in Warehousing“. In: *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2026)*. Status: eingereicht. Italien, 2026

Friedrich Niemann u. a. „Towards Standardized Dataset Creation for Human Activity Recognition: Framework, Taxonomy, Checklist, and Best Practices“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_5

4.1 Explorative Studie zur kontextsensitiven Aktivitätserkennung | CAARL

Die kontextsensitive Aktivitätserkennung ist in der Intralogistik bislang nicht erforscht. Diese explorative Studie untersucht den Einfluss positionsbezogener Kontextinformationen auf die Aktivitätserkennung. Dazu wird der *Context-Aware Activity Recognition in Logistics (CAARL)*-Datensatz vorgestellt und eine Methode zur kontextsensitiven Aktivitätserkennung exemplarisch angewendet. Ziel der Studie ist die Identifizierung relevanter Zusammenhänge und die Ableitung von Modellannahmen, die als Grundlage für die Entwicklung aktivitäts- und kontextsensitiver Methoden der Prozesserkennung sowie für die Erstellung eines prozesszentrierten Datensatzes dienen.

4.1.1 Erstellung des CAARL-Datensatzes

CAARL [Nie+21a; Nie+21b] ist ein Datensatz mit kontextbasierten Lokalisierungs- und aktivitätsbasierten Bewegungsdaten von Personen und Objekten (siehe Abbildung 4.1). Die Bewegungen wurden in einem Labor mittels oMoCap-System und einer Videokamera aufgenommen. Insgesamt umfasst der Datensatz 140 Minuten Aufnahmen.



Abb. 4.1 Logo des CAARL-Datensatzes. Der Datensatz und das Logo stellen den Menschen sowie dessen Hilfsmittel und weitere Objekte dar, die mittels oMoCap erfasst und als markerbasierte Skelette visualisiert werden.

Szenarien

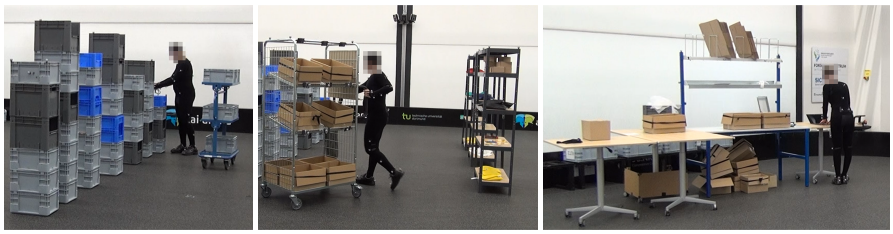
Intralogistikprozesse wurden in einem kontrollierten Laboraufbau physisch nachgestellt. Es wurden zwei Kommissionierszenarien (L01, L02) sowie ein Verpackungsszenario (L03) untersucht (siehe Abbildung 4.2).

L01 bildet ein vereinfachtes PzW-Kommissionierprinzip ab, bei dem kleine Artikel aus Regalen oder Kisten entnommen, auf einem kleinen Kommissionierwagen gesammelt und anschließend auf einer Basis abgestellt werden.

L02 basiert auf einem realen Kommissionier- und Konsolidierungssystem und erweitert L01 um zusätzliche Prozessschritte. Die Artikel werden gescannt, in Kartons auf einem großen Kommissionierwagen abgelegt, per PtL quittiert, gestempelt und anschließend im Durchlaufregal konsolidiert.

L03 bildet einen realen Verpackungsprozess ab. Die in L02 kommissionierten Artikel werden zum Verpackungstisch transportiert, gewogen, gegebenenfalls sortiert und versandfertig, inklusive Füllmaterial, Lieferschein und

Barcode, verpackt. Eine detaillierte Beschreibung der Szenarien findet sich in [Nie+20a, S. 6–12].



(a) L01: vereinfachtes Kommissionierszenario

(b) L02: reales Kommissionier- und Konsolidierungsszenario

(c) L03: reales Verpackungsszenario

Abb. 4.2 Exemplarische Darstellung des Laboraufbaus der drei Logistikszenarien

Objekte und Aufbau der Aufnahmeumgebung

Der Versuchsaufbau umfasste zwölf mit Markern ausgestattete Objekte, darunter Kommissionierwagen, Regale, Raumeingänge und einen Verpackungstisch (siehe Abbildung 4.3). Nicht alle Objekte wurden in jedem Szenario genutzt, jedoch stets vollständig aufgezeichnet, sodass alle Datensatzdateien unabhängig vom Szenario identisch strukturiert sind.

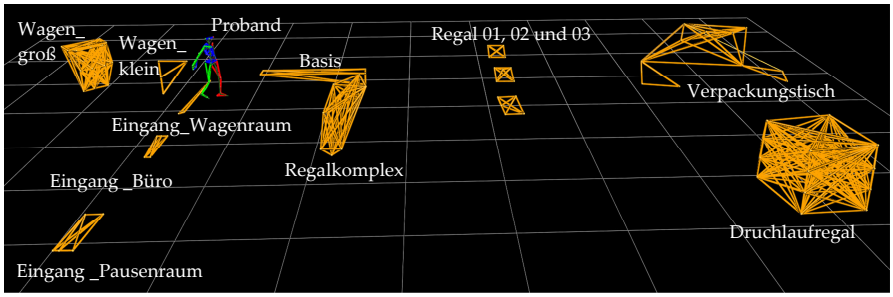


Abb. 4.3 oMoCap-Rekonstruktion des Versuchsaufbaus mit Probanden und Objekten, dargestellt als Skelettmodelle

Zur Erfassung starrer Objekte waren mindestens drei dauerhaft sichtbare Marker mit individuellem Muster erforderlich; eine höhere Markeranzahl erhöhte die Robustheit der Schätzung. Insgesamt wurden 94 Marker auf die zwölf Objekte verteilt.

Die Objekte wurden vor der Aufnahme in der Nexus-Software gespeichert, wodurch nicht nur Objekte, sondern auch einzelne Marker identifiziert werden konnten. Dies ermöglichte die Erkennung von Unterkomponenten wie Griffen am Kommissionierwagen, Regalebenen oder Bedienelementen. So umfasste der Verpackungstisch elf Marker, welche kleinere Elemente wie den Behälter mit Luftpolsterfolie, die Waage oder den Computer modellierten (siehe Abbildung 4.4).

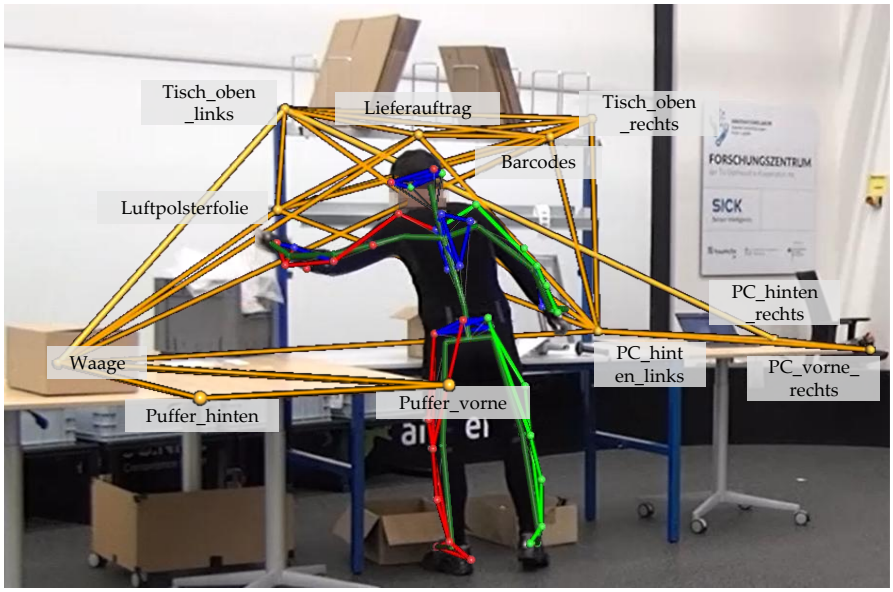


Abb. 4.4 Räumliche Zuordnung der oMoCap-Markern und rekonstruierten Skelettmodellen zum realen Verpackungsszenario anhand einer Bildüberlagerung

Probanden und Aufnahmen

An der Datenaufnahme nahmen zwei Probanden (weiblich, 26 Jahre; männlich, 30 Jahre) teil, die jeweils 70 Minuten aufgezeichnet wurden. Zur Erfassung von Probanden und Objekten kamen ein markerbasiertes oMoCap-System sowie eine Videokamera zum Einsatz; die Probanden trugen einen oMoCap-Anzug mit 39 optischen Markern. Die Aufnahmen wurden in zweiminütige Sequenzen unterteilt und umfassen pro Proband fünf Sequenzen aus Logistikszenario L01 sowie jeweils 15 aus den Szenarien L02 und L03, insgesamt 140 Minuten.

Alle Aufnahmen fanden am selben Tag unter unveränderten Umgebungs- und Sensoreinstellungen statt. Die Szenarien wurden ohne Unterbrechungen durchgeführt, wobei Prozessschritte durch Logistikexperten erläutert wurden, jedoch ohne Vorgaben zur konkreten Bewegungsausführung, um natürliche Bewegungen zu gewährleisten. Das oMoCap-System zeichnete Markerpositionen mit 200 frames per second (fps) auf; Rekonstruktion und Annotation erfolgten nach Abschluss aller Aufnahmen, sodass nur minimale Zeitversätze zwischen den Aufnahmesequenzen auftraten.

Annotation und Revision

Die Auswertung der Aufnahmen erfolgte zweistufig. Zunächst wurden die oMoCap-Daten in Ein-Sekunden-Fenstern segmentiert und sieben Haupt- sowie 19 Teilaktivitäten mithilfe eines zeitlichen TCNN automatisch klas-

sifiziert. Anschließend revidierten zwei Experten die Labels und Segmentgrenzen manuell. Der Revisionsaufwand betrug insgesamt 44,72 Stunden, entsprechend 19,17 Minuten pro Minute Aufnahme.

Die Hauptaktivitäten umfassen Fortbewegung (*Stehen*, *Gehen*, *Wagen*), die etwa 30 % des Datensatzes ausmachen, sowie Handhabungsaktivitäten mit rund 70 % (siehe Tabelle 4.1). Das Klassenlabel *Handhabung neutral* dominiert mit 64,9 %, was insbesondere auf Szenario L03 zurückzuführen ist, in dem die meisten Bewegungen am Verpackungstisch auf Bauch- und Brusthöhe ausgeführt wurden. Ein zusätzliches Klassenlabel (*Keine*) erfasst nicht zuordenbare Bewegungen und fehlerhafte oMoCap-Daten. Die Hauptaktivitäten werden durch 19 binäre Teilaktivitäten beschrieben die Bein-, Oberkörper- und Handbewegungen sowie die Gegenstandshaltung abbilden. Eine Beschreibung der Haupt- und Teilaktivitäten ist [Nie+20a, S. 15–19] zu entnehmen. Aufgrund der Kombinationen ergeben sich 123 eindeutige Labelrepräsentationen.

Tabelle 4.1 Annotationsergebnisse nach Klassenlabels unterteilt

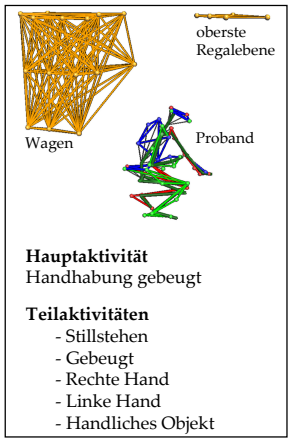
Klassenlabel		Frames		Segmentlänge in Frames			
ID	Name	Nr.	%	Nr.	%	Min.	Max.
k_1	**Stehen**	112.228	6,68	349	7,41	32	2.600
k_2	**Gehen**	181.596	10,81	258	5,47	61	8.800
k_3	**Wagen**	207.774	12,37	191	4,05	87	4.400
k_4	**Handhabung überkopf**	137.911	8,21	492	10,44	35	1.400
k_5	**Handhabung neutral**	954.959	56,84	3.134	66,50	26	4.607
k_6	**Handhabung gebeugt**	72.368	4,31	280	5,94	36	1.800
k_7	**Keine**	13.164	0,78	9	0,19	200	3.000
	Gesamt	**1.680.000**	**100**	**4.713**	**100**		

Die beispielhafte annotierte Sequenz in Abbildung 4.5 zeigt die Segmentierung einer 20-sekündigen Szene aus Szenario L02, die verschiedene Kombinationen aus Fortbewegung, Handhabung, Haltung und Objektinteraktion repräsentieren.

4.1.2 Methodik der kontextsensitiven Aktivitätserkennung

Die verwendete HAR-Architektur, basierend auf [Lüd+21], kombiniert Bewegungs- und Kontextdaten zur Aktivitätsklassifikation. Trainings-Hyperparameter und Versuchsprotokoll sind in [Nie+21b] dokumentiert.

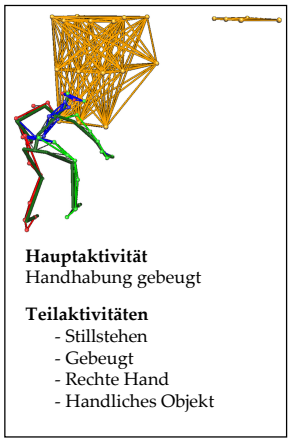
Kern der Methode ist ein auf dem LARa-Datensatz [Nie+20a] vortrainiertes TCNN [Nie+20c] zur Schätzung von Bewegungsdeskriptoren (Teilaktivitäten) aus Sensordaten (siehe Abbildung 4.6). Das TCNN [Grz+17; RC15;



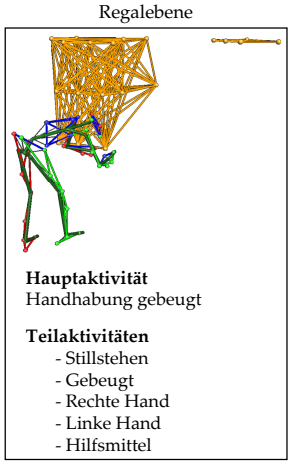
(a) Proband greift nach einem Artikel in einer unteren Regalebene



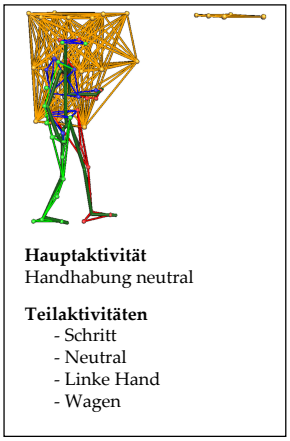
(b) Proband transportiert den Artikel zum Wagen



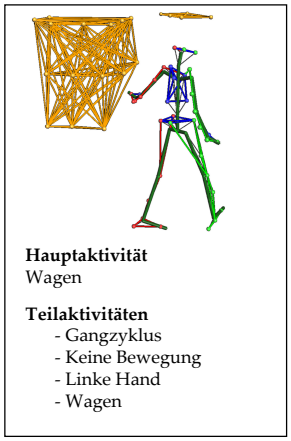
(c) Proband legt den Artikel in den Wagen ab



(d) Proband quittiert die Abgabe durch das Drücken einer Taste am Wagen



(e) Proband greif nach dem Wagen



(f) Proband zieht den Wagen hinter sich her

Abb. 4.5 Exemplarische Annotationssequenz von sechs Segmenten einer oMoCap-Aufnahme

Yao+18] umfasst vier Faltungsschichten, zwei Fully-Connected-Schichten und eine Sigmoid-Ausgabe mit 19 Attributen.

Da Kontextdaten nicht direkt im TCNN verarbeitet werden, werden die geschätzten Attributswahrscheinlichkeiten gemeinsam mit den Kontextmerkmalen einem nachgelagerten flachen Klassifikator (QDA, eXtreme Gradient Boosting (XGBoost), RF) übergeben. Dieser wird auf vorab berechneten Netzwerkausgaben trainiert und bestimmt daraus die Klasse der Hauptaktivität. Diese Architektur ermöglicht die Integration von Kontextdaten, ohne ein erneutes Training des gesamten Netzes.

Die Motivation: Die Merkmalsextraktion aus Bewegungsdaten ist komplex, aber domänenunabhängig und daher vortrainierbar; die Kontextintegration ist anwendungsspezifisch und wird im nachgelagerten Klassifikator gelernt. Das Training des Klassifikators entspricht einer Form des *Fine-Tuning*, einer gängigen Technik im Deep Learning [Käd+17].

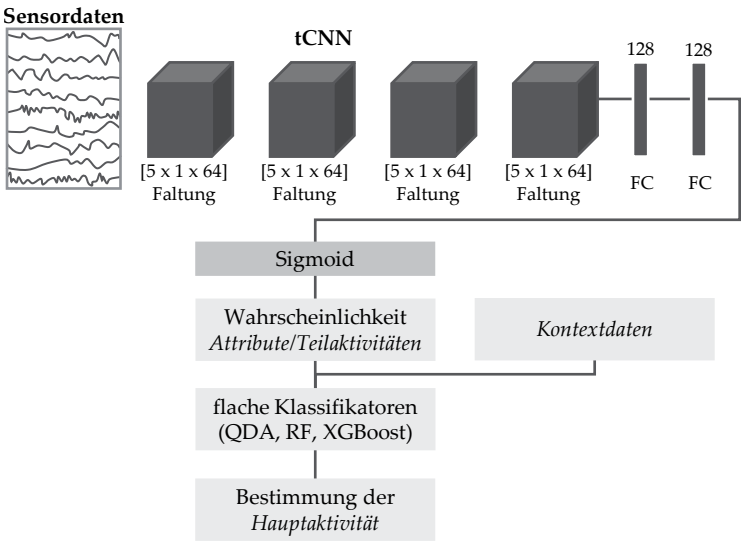


Abb. 4.6 Architektur der kontextsensitiven Aktivitätserkennung (angelehnt an [Lüd+21])

4.1.3 Evaluation der kontextsensitiven Aktivitätserkennung

Die Evaluation umfasst einen Vergleich der vorgeschlagenen Methode mit einem Basismodell, welches ausschließlich auf die Attributschätzungen eines vortrainierten Attributklassifikators zurückgreift [Nie+20a]. Für die Fusion von Attribut- und Kontextmerkmalen werden drei flache Klassifikatoren QDA, XGBoost und RF evaluiert, um Hauptaktivitätsklassen vorherzusagen. Die Kontextinformationen werden dabei sowohl als segmentierte Rohdaten der Umgebungsmarker als auch in Form vorab berechneter paarweiser Distanzen zwischen 25 ausgewählten Umgebungsmarkern und den Markern an der linken Hand, der rechten Hand sowie an der Brust des Probanden berücksichtigt.

Tabelle 4.2 zeigt das Makro-F1-Maß der Modelle. Das RF übertraf QDA in allen und XGBoost in allen außer dem Distanzfall; QDA konnte wegen der hohen Dimensionalität nicht auf Rohdaten angewendet werden. Das RF-Basismodell (mit nur Attributschätzungen) erreichte einen Makro-F1 von 71,6. Durch Kontextdaten stieg die Leistung auf 73,3 (Attribute+Distanz) bzw. 82,0 (Attribute+Rohkontext). Der Rohkontext war damit Distanzmerkmalen klar überlegen; selbst ohne Attribute übertraf er bereits das Basismodell,

während die Kombination beider Informationsquellen die beste Leistung erzielte.

Tabelle 4.2 Makro-F1-Maß verschiedener Klassifikatoren und Merkmalsuntergruppen

Klassifikator	Attr. (Basismodell)	Dist	Attr. + Dist	Roh	Attr. + Roh
QDA	67,0	51,5	61,9	–	–
XGBoost	71,7	73,0	64,3	69,1	72,7
RF	71,6	64,6	73,3	74,5	82,0

Anmerkung: Attr. = Attribut, Dist = Distanz, Roh = Rohdaten

Das klassenweise F1-Maß zeigt große Leistungsunterschiede (siehe Tabelle 4.3). Die Klasse *Stehen* blieb unabhängig von den Inputdaten schwierig zu erkennen. Rohkontext verbesserte drei Klassen (*Wagen*, *Handhabung überkopf*, *Gehen*), verschlechterte jedoch drei andere (*Handhabung neutral*, *Handhabung gebeugt*, *Stehen*). Trotzdem stieg der Makro-F1 deutlich an.

Tabelle 4.3 Klassenweises F1-Maß des RF-Modells

	Stehen	Gehen	Wagen	Handhabung		
				überkopf	neutral	gebeugt
Attr. (Basismodell)	21,0	74,3	80,9	88,0	76,1	81,5
Dist	6,3	71,6	81,9	85,8	50,8	59,3
Attr. + Dist	15,6	84,2	88,0	88,6	74,3	82,2
Roh	21,4	82,3	80,3	80,8	68,7	80,4
Attr. + Roh	15,0	83,3	88,0	82,5	75,3	82,6

Zur Identifikation relevanter Merkmale für die Aktivitätserkennung wurde die heuristische Methode der Greedy-Feature-Auswahl eingesetzt [Kha+17]. Die Ergebnisse (siehe Tabellen 4.4 bis 4.6) zeigen, dass nur wenige Merkmale aufgenommen wurden, bis kein weiteres einzelnes Feature den F1-Maß mehr erhöhte. Dieses Verhalten ist darauf zurückzuführen, dass der Greedy-Feature-Ansatz lediglich zu einem lokalen Minimum konvergiert. Dadurch bleiben potenzielle Leistungsgewinne durch Wechselwirkungen mehrerer Merkmale unberücksichtigt. Aufgrund der zufallsbasierten Datenaufteilung im Kreuzvalidierungsverfahren stimmen die Ergebnisse der Basismodelle nicht exakt mit den Basismodellen in Tabelle 4.2 überein.

Insgesamt führen bereits wenige Kontextmerkmale zu einer Verbesserung der HAR-Leistung. Besonders starken Einfluss haben Marker an Wagen und Tisch: Wagenbewegungen weisen auf die Aktivität *Wagen* hin, während Tischnähe auf Handhabungsaktivitäten hindeutet. Die Verwendung sämtlicher Kontextmerkmale steigert die Leistung weiter, geht jedoch mit erhöhtem Erfassungsaufwand einher. Die Wahl der Kontextmerkmale stellt daher einen

Zielkonflikt zwischen Aufnahmekosten und der für nachgelagerte Aufgaben benötigten Genauigkeit dar.

Tabelle 4.4 Ergebnisse der Greedy-Feature-Auswahl (QDA, Distanzmerkmale)

Marker 1	Marker 2	F1-Maß
Attribute (Basismodell)		68,0
+ Kommissionierwagen_groß_Put-to-Light-Taste	Proband_rechter_Finger	69,8
+ Verpackungstisch_Barcode	Proband_rechter_Finger	70,5
+ Kommissionierwagen_klein_Griff	Proband_rechter_Finger	71,1
+ Kommissionierwagen_klein_hinten	Proband_rechter_Finger	71,8
+ Kommissionierwagen_klein_hinten	Proband_linker_Finger	71,9
+ Verpackungstisch_Luftpolsterfolie	Proband_linker_Finger	71,9

Tabelle 4.5 Ergebnisse der Greedy-Feature-Auswahl (RF, Distanzmerkmale)

Marker 1	Marker 2	F1-Maß
Attribute (Basismodell)		71,7
+ Verpackungstisch_Barcodes	Proband_linker_Finger	74,0

Tabelle 4.6 Ergebnisse der Greedy-Feature-Auswahl (RF, Rohdaten)

Marker	Axe	F1-Maß
Attribute (Basismodell)		71,7
+ Verpackungstisch_oben_rechts	z	74,8
+ Kommissionierwagen_klein_Griff	y	76,1

4.1.4 Schlussfolgerungen für die Prozesserkennung

Die explorative Studie zeigt, dass der Einbezug von Kontextinformationen die Leistungsfähigkeit der Aktivitätserkennung deutlich erhöht. Bewegungs- und Kontextdaten weisen dabei eine klare Korrelation auf und werden methodisch gemeinsam ausgewertet. Eine solche Merkmalsfusion eignet sich folglich auch zur Prozessidentifikation, sofern Prozesse über Lokalisierung von Menschen und/oder deren Aktivitäten beschreibbar sind.

Zugleich wurden besonders aussagekräftige Kontextmerkmale identifiziert. Bereits wenige Lokalisierungsinformationen führen zu messbaren Leistungsgewinnen. Im CAARL-Datensatz erwiesen sich insbesondere die Lokalisierung des Kommissionierwagens, des Probanden und des Verpackungstisches als relevant für die Aktivitätserkennung. Dies ist plausibel, da die räumliche Nähe zu Verpackungstisch oder Wagen unmittelbar auf

den aktuellen Prozessschritt schließen lässt und damit den Raum möglicher Aktivitäten stark einschränkt. Aufgrund der weitgehend standardisierten Abläufe in der Intralogistik erscheint es sinnvoll, zukünftige Datensätze auf diese drei Entitäten zu fokussieren. Weiterhin zeigte die Datensatzerstellung erneut den Mangel an klaren Richtlinien für die Erhebung und Dokumentation entsprechender HAR-Datensätze auf.

4.2 Entwicklung eines aktivitäts- und kontextsensitiven Prozesserkennungsverfahrens

Interpretation der explorativen Studie

Die explorative Studie zeigt eine enge Wechselbeziehung zwischen Kontextinformationen und menschlichen Aktivitäten. Lokalisierungsinformationen verbessern einerseits die Erkennungsleistung von Aktivitäten. Andererseits liefert – wie in Abbildung 4.5 dargestellt – die räumliche Position einer Person im Gesamtsystem und relativ zu Objekten und Hilfsmitteln entscheidende Hinweise, um menschliche Bewegungen in einen prozessualen Kontext einzuordnen. Dadurch lassen sich wiederkehrende Bewegungsabläufe identifizieren, die den Ablaufabschnitten einer REFA-Zeitstudie entsprechen (siehe Abschnitt 2.2.3).

Auf Grundlage dieser Beobachtungen wird die Hypothese formuliert, dass für die automatische Erkennung von Prozessen mindestens zwei Informationsquellen erforderlich sind: die Hauptaktivität einer Person sowie deren räumliche Lokalisierung. Zusätzliche Informationen, etwa Teilaktivitäten oder weitere Kontextdaten, verbessern das Prozessverständnis potenziell weiter. Im weiteren Verlauf der Arbeit wird daher untersucht, welche Inputinformationen geeignet sind, eine hohe Prozesserkennungsleistung zu erreichen, wobei zugleich das Aufwand-Nutzen-Verhältnis der Datenerhebung berücksichtigt wird.

Modulare Datenverarbeitungskette

Aus den bisherigen Erkenntnissen lässt sich eine modulare Datenverarbeitungskette von der HAR und HCR hin zur Prozesserkennung ableiten (siehe Abbildung 4.7). In den ersten beiden Schritten der Verarbeitungskette werden Aktivitäten von Mitarbeitenden erkannt und deren Lokalisierung bestimmt.

HCR: Die Indoorlokalisierung erfolgt beispielsweise über Multilateration von Sensorsignalen, etwa mittels Bluetooth Low Energy (BLE), Ultra-Wideband, WLAN, 5G oder RFID. Eine hochauflösende Positionsbestimmung, wie sie mit oMoCap-Systemen in der explorativen Studie CAARL möglich war, ist in der Praxis nur bedingt umsetzbar. In industriellen Anwendungen kommen derzeit überwiegend Beacons oder 5G zum Einsatz, um Mitarbeitenden vordefinierte Zonen zuzuordnen. Die genannten Sen-

sortechnologien zeichnen sich durch eine flexible Implementierung sowie vergleichsweise geringe Kosten aus.

HAR: Für die Aktivitätserkennung existiert eine Vielzahl etablierter Methoden. Ein möglicher Ansatz wurde im Rahmen der explorativen Studie CAARL vorgestellt, in der ein TCNN eingesetzt wurde. In praktischen Anwendungen werden häufig IMUs als Eingabedaten verwendet, da diese Sensoren kostengünstig, robust und einfach im Lager zu implementieren sind. Zusätzlich lassen sich Lokalisierungsinformationen als ergänzende Kontextdaten nutzen, um die Erkennungsleistung der Aktivitätsklassifikation zu verbessern, wie in Abschnitt 4.1 gezeigt wurde.

Prozesserkennung: Die Prozesserkennung baut auf den Ergebnissen der Aktivitätserkennung sowie der Indoorlokalisierung auf, indem deren Klassifikationslabels als Eingabedaten verwendet werden. Ebenso lassen sich weitere Kontextinformationen integrieren. Insbesondere erscheint die Einbindung eines idealisierten Prozessmodells, beispielsweise in Form von Business Process Model and Notations (BPMNs), sinnvoll.

Eine zentrale Herausforderung der Prozesserkennung besteht in der Modellierung zeitlicher Abhängigkeiten. Während Aktivitäten häufig unabhängig voneinander klassifiziert werden und somit eine fensterbasierte Betrachtung einzelner Zeitabschnitte ausreicht, stehen Prozessschritte in einer zeitlichen Abfolge und bauen aufeinander auf. Eine isolierte Betrachtung einzelner Zeitfenster ist daher nur eingeschränkt möglich; vielmehr erfordert die Prozesserkennung die Berücksichtigung längerer zeitlicher Zusammenhänge.

Modelle wie TCNN, die für die Aktivitätserkennung geeignet sind, berücksichtigen diese sequenziellen Abhängigkeiten nicht. Daher werden für die Prozesserkennung Sequenzmodelle untersucht, die zeitliche Zusammenhänge explizit modellieren. Dazu zählen LSTM, Transformer sowie HMM. LSTM stellt eine spezielle Form eines (Recurrent Neural Network (RNN)) dar und ermöglicht die Modellierung langfristiger Abhängigkeiten in sequenziellen Daten, indem jeder Zeitschritt auf dem vorherigen Zustand aufbaut. HMM hingegen beschreibt Sequenzen über verborgene Zustände, wobei der aktuelle Zustand ausschließlich vom vorherigen Zustand abhängt. Transformer [SK21] modellieren Sequenzen dagegen nicht rekurrent, sondern parallel über Self-Attention Mechanismen.

Schlussfolgerung für die weitere Arbeit

Die Indoorlokalisierung sowie die HAR stellen etablierte Forschungsfelder dar und werden bereits in praktischen Anwendungen der Intralogistik und Produktion eingesetzt. Der Fokus dieser Arbeit liegt daher auf dem Abschnitt der Prozesserkennung (siehe rechter Teil der Datenverarbeitungskette in Abbildung 4.7).

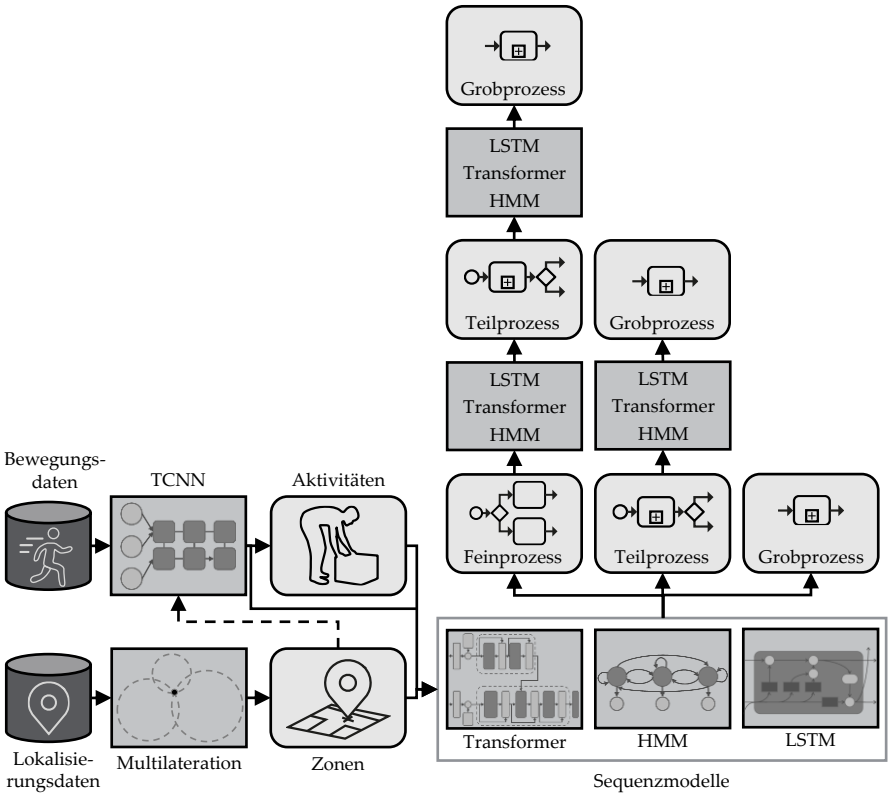


Abb. 4.7 Modulare Datenverarbeitungskette für die aktivitäts- und kontextsensitive Erkennung menschenzentrierter Prozesse

Zur Evaluation der betrachteten Sequenzmodelle wird ein intralogistischer Datensatz benötigt, der sowohl Aktivitäts- als auch Kontextlabels enthält. Voraussetzung für die Erstellung eines solchen Datensatzes ist ein geeignetes Framework zur Datensatzerstellung, das im folgenden Abschnitt entwickelt wird.

4.3 Framework zur Datensatzerstellung

Als Reaktion auf fehlende Standards in der Datensatzerstellung wurde mit [Rei+23] ein erster Ansatz zur Standardisierung der Erstellung von HAR-Datensätzen vorgestellt. Aufbauend darauf wird in dieser Arbeit ein erweitertes Vorgehen entwickelt, das auf den Erkenntnissen der Literaturrecherchen (Abschnitte 3.1 und 3.2), der Datensatzrecherche (Abschnitt 3.3) sowie der explorativen Studie CAARL (Abschnitt 4.1) basiert. Dieses Vorgehen wird im Rahmen dieser Arbeit in ein Framework überführt und als benutzerfreundliche HAR-Checkliste operationalisiert, angelehnt an Checklistenmodelle aus medizinischen Studien.

Das entwickelte Framework umfasst sechs Phasen (siehe Abbildung 4.8). Der Rahmen bildet die Planung (Phase 1) und die Veröffentlichung (Phase 6) eines Datensatzes. In dem Rahmen finden die Datenaufnahme (Vorbereitung und Durchführung) in den Phasen 2 und 3 sowie die Datenverarbeitung (Vorbereitung und Durchführung) in den Phasen 4 und 5 statt.

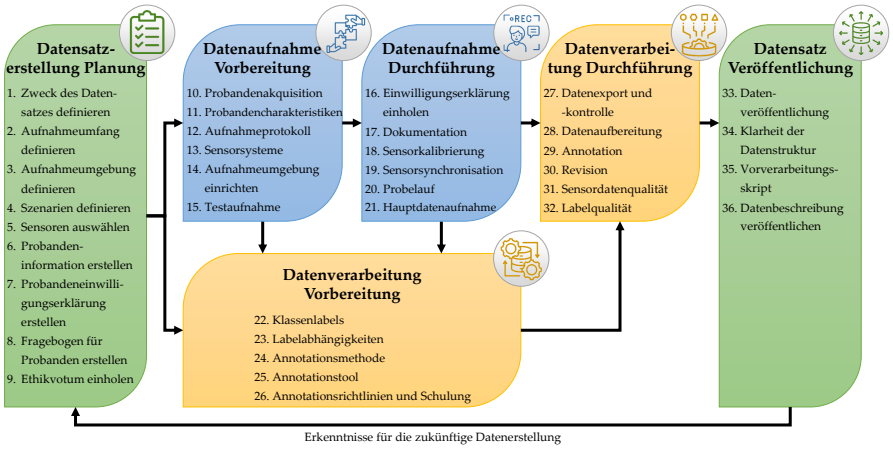


Abb. 4.8 Framework zur Datensatzerstellung

4.3.1 Phase 1 | Planung der Datensatzerstellung

Die Schritte 1 bis 9 des Frameworks definieren die allgemeinen Parameter der Datensatzerstellung und identifizieren Herausforderungen und Einschränkungen. Diese sind bereits vor der Datenaufnahme zu planen und durchzuführen.

1. Zweck des Datensatzes definieren: Der Zweck des Datensatzes ist von Anfang an klar zu definieren und auf einen bestimmten Forschungs- oder industriellen Anwendungsbereich (siehe Tabelle 4.7) abzustimmen. Ziel ist es, eine klare Grundlage hinsichtlich der Gründe für die Erstellung des Datensatzes, seiner Zielgruppe, potenzieller Anwendungen und seiner übergeordneten Ziele zu schaffen, die gemeinsam als Leitprinzipien für den gesamten Erstellungsprozess dienen.

2. Aufnahmeumfang definieren: Der erforderliche Aufnahmeumfang eines Datensatzes lässt sich aus seinem definierten Zweck ableiten, während der realisierbare Umfang unter Berücksichtigung der verfügbaren Ressourcen wie Zeit, Finanzierung, Erfassungsumgebung, Sensorinfrastruktur und Personalkapazitäten bewertet wird.

Im Vergleich zur nachgelagerten Annotation und Revision ist die Datenaufnahme in der Regel weniger zeitintensiv. Mit zunehmender Komplexität

Tabelle 4.7 Taxonomie der Datensatzerstellung: HAR-Anwendungsbereiche; basierend auf [Bed+20; KCA24; Min+20; MP19; NSA25; SAG25]

Kategorie	Realisierungsoptionen	
HAR-Anwendungsbereiche	Gesundheitswesen / Rehabilitation	Bewegung und Sport
	Verkehr und Mobilität	Smart Homes und AAL
	Unterhaltung und Spiele	Verhaltensforschung / Psychologie
	Robotik/Mensch-Maschine-Interaktion	Industrie (Produktion / Logistik)
	Sicherheit und Überwachung	andere

Anmerkung: AAL

des Label-Sets sinkt zudem der relative Aufwand für die Datenaufnahme deutlich. So entfielen beim *LARa*-Datensatz lediglich 24,20 % des Gesamtaufwands auf die Datenaufnahme, während die Annotation von 27 Haupt- und Teilaktivitätslabeln 58,23 % und die anschließende Revision 17,57 % des Aufwands beanspruchten [Nie+20c].

3. Aufnahmeumgebung definieren: Die Aufnahmeumgebungen lassen sich in drei Kategorien einteilen: *kontrollierte Umgebungen* (z. B. Labore und oMoCap-Studios), *teilweise kontrollierte Umgebungen* (z. B. simulierte Wohnungen, Rehabilitationszentren und simulierte Lagerhäuser) und *reale Umgebungen* (z. B. Privathäuser, Arbeitsplätze und Industrieanlagen), siehe Tabelle 4.8.

Tabelle 4.8 Taxonomie der Datensatzerstellung: Aufnahmeumgebungen

Kategorie	Realisierungsoptionen	
Aufnahmeumgebungen	kontrollierte Umgebung	teilweise kontrollierte Umgebung
	reale Umgebung	

Kontrollierte Umgebungen bieten standardisierte Bedingungen, geringe externe Störungen und eine hohe Reproduzierbarkeit (z. B. *WISDM Activity Prediction* [KWM11; WISDM12]). Eine zentrale Herausforderung besteht darin, die Umgebungen realitätsnah zu gestalten, um geeignete Datensätze für das Training praxistauglicher HAR-Anwendungen zu erzeugen. Andernfalls besteht die Gefahr, dass beobachtete Bewegungsmuster nur eingeschränkt auf reale Anwendungsszenarien übertragbar sind.

Teilweise kontrollierte Umgebungen kombinieren laborähnliche Kontrolle mit realitätsnahen Szenarien, wie Miniaturlager oder simulierte Wohnumgebungen zur Nachbildung alltäglicher Aktivitäten (z. B. *Opportunity* [Opport12; Rog+10]).

Reale Umgebungen wie Wohnungen, Büros, Trainingsstudios oder Produktions- und Lagerstätten ermöglichen die Erfassung natürlich auftretender Aktivitäten (z. B. *WISDM Actitracker* [Loc+11; WISDM13]). Gleichzeitig schränkt jedoch die verwendete Sensortechnologie den Grad der Authentizität ein. Als Folge sind solche Aufnahmen komplexer und anfälliger für unkontrollierte Einflüsse, was zusätzliche Anforderungen an Annotation, Qualitätssicherung und Modellrobustheit mit sich bringt.

4. Szenario definieren: Ein Szenario bezieht sich auf eine strukturierte Beschreibung und Gestaltung des situativen Kontexts, in dem Daten erfasst werden. Szenarien lassen sich in drei Haupttypen einteilen (siehe Tabelle 4.9).

Tabelle 4.9 Taxonomie der Datensatzerstellung: Szenarien

Kategorie	Realisierungsoptionen	
Szenarien	skriptbasiert	unter Alltagsbedingungen
	hybrid (Kombination: Skript und Alltag)	

In *skriptbasierten Szenarien* folgen Probanden einer vordefinierten Abfolge von Aufgaben, die von komplexen Abläufen (z. B. *Opportunity* [Opport12; Rog+10]), über Kochsequenzen mit Mikro- und Makroaktivitäten [Lag+20] bis zu isolierten oder ungeordnete Aktivitäten reichen (z. B. *WISDM* [KWM11; WISDM12], *RealWorld* [RealWorld16; SS16]). Diese kontrollierten Designs ermöglichen eine hohe Vergleichbarkeit, schränken jedoch natürliche Bewegungs- und Verhaltensmuster ein, weshalb eine Minimierung experimenteller Vorgaben zur Erhaltung der Verhaltensvariabilität erforderlich ist.

Szenarien unter Alltagsbedingungen erlauben die unbeeinflusste Ausführung privater oder beruflicher Aktivitäten im natürlichen Umfeld (z. B. *APTURE-24* [Cha+21; Cha+24], *ETRI* [Chu+22; ETRI21]). Trotz höherer Komplexität der Annotation führen solche Daten in der Regel zu robusteren und besser generalisierbaren Modellen.

Hybride Szenarien kombinieren beide Ansätze, indem Probanden allgemeine Aufgaben mit flexibler Ausführung erhalten. Der *CLAD*-Datensatz [Tay+18; THC17] verfolgt dieses Konzept, um Realismus und Konsistenz auszubalancieren.

5. Sensoren auswählen: Die Wahl des Sensors (siehe Tabelle 4.10) hängt vom Verwendungszweck, Anwendungsbereich, der Verfügbarkeit der Infrastruktur und dem Budget ab. IMUs werden aufgrund ihrer Kosteneffizienz, Verfügbarkeit, ihres geringen Stromverbrauchs, der Robustheit und der angemessenen Genauigkeit [Dem+20] häufig verwendet und sind in Verbrauchergeräten wie Smartphones und Smartwatches integriert [Hom+25].

Positionssensoren wie GPS (z. B. *Daily Log* [DailyLog16; Szt+16] und *RealWorld* [RealWorld16; SS16]), RFID (z. B. *CMU-MMAC* [Kitch09; SDH09]) und Beacon, sowie *Biosensoren* (z. B. Herzfrequenzmesser wie *PAMAP2* [Rei12; RS12] und Körpermedien wie *CMU-MMAC* [Kitch09; SDH09]) und *taktile Sensoren und Kraftsensoren* (z. B. *AndyData-lab-onePerson* [Mau+19a; Mau+19b]) sind weitere, seltener verwendete Optionen. Diese Arten von Sensoren werden in der Regel als ergänzende Datenquellen eingesetzt, um die Robustheit der Aktivitätserkennung zu verbessern und Kontextinformationen wie Positionsdaten und Zustände von Personen und ihrer Umgebung zu erfassen.

6. Probandeninformation erstellen: Den Probanden ist ein transparentes [Ema00] und verständliches Informationsdokument bereitzustellen, in dem der Zweck der Studie, potenzielle Risiken sowie der Umgang mit den erhobenen Daten erläutert werden. Leitlinien wie *Guideline for Good Clinical Practice* (ICH-GCP E6 R2) der International Council for Harmonisation [ICH16], die Richtlinien des *Council for International Organizations of Medical Sciences* (CIOMS) [Cou16] und die Deklaration von Helsinki der *World Medical Association* (WMA) [Wor13] definieren die Kernelemente, die entsprechende Dokumente in Studien mit menschlicher Beteiligung enthalten.

7. Probandeneinwilligungserklärung erstellen: Die informierte Einwilligung ist aus ethischer [OECD13], rechtlicher [Eur16] und wissenschaftlicher [ICH16] Sicht für jede Studie mit menschlichen Probanden unerlässlich. Sie ist vor der Datenerhebung einzuholen und umfasst die Genehmigung für bestimmte Datentypen und Anwendungsfälle, wodurch die Rechte der Probanden geschützt und die Integrität der Forschung sichergestellt wird. Diese Grundsätze sind in internationalen Richtlinien wie der Deklaration von Helsinki [Wor13] und institutionellen Vorgaben [Cou23; council19; HP25; HSP25a; HSP25b; Sie15] verankert.

Gleichzeitig bildet die informierte Einwilligung eine zentrale Rechtsgrundlage für die Datenverarbeitung gemäß der EU-Datenschutz-Grundverordnung (DSGVO) [Eur16] und ist für die Reproduzierbarkeit und Glaubwürdigkeit wissenschaftlicher Daten notwendig [ICH16]. In Beschreibungen von HAR-Datensätzen wird sie jedoch selten explizit erwähnt; eine Ausnahme stellt der *CSL-SHARE*-Datensatz [LHS21] dar, in dem der Einwilligungsprozess dokumentiert ist.

Tabelle 4.10 Taxonomie der Datensatzerstellung: Sensortypen; basierend auf [Bia+22; Fu+20; KRK24; Liu+25; OOA24; Whi87; YLC20]

Sensortypen	Sensor	
Trägheitssensoren	Beschleunigungsmesser	Gyroskop
	Magnetometer	
Visuelle Sensoren	RGB-Kamera	Tiefenkamera
	Infrarotkamera	Stereokamera
Physiologische/ Biosensoren	Elektromyographie (EMG)	Elektrokardiographie (EKG)
	Elektroenzephalographie (EEG)	galvanische Hautreaktion (GSR)
	Herzfrequenzsensor	Hauttemperatursensor
Akustische Sensoren	Mikrofon	Oberflächenwellen-Sensor
	Ultraschallmikrofon	
Umgebungssensoren	Barometer	Temperatursensor
	Umgebungslichtsensor	Feuchtigkeitssensor
Positionssensoren	GPS	Ultrabreitband (UWB)
	RFID-/NFC-Tag	Bluetooth Low Energy (BLE)
	WiFi-Fingerprinting	5G-Ortung
	visionsbasierte Lokalisierung	akustische Lokalisierung
Taktile Sensoren und Kraftsensoren	Drucksensor	Kraftsensor
	Dehnungsmessstreifen	Wägezelle
	taktile Sensoranordnung	

8. Fragebogen für Probanden erstellen: Standardisierte Fragebögen dienen der systematischen Erfassung studienrelevanter Informationen, beispielsweise von Probandencharakteristiken, zur Unterstützung der Dateninterpretation sowie zur Sicherstellung der Einhaltung von Ein- und Ausschlusskriterien.

9. Ethikvotum einholen: Die ethische Genehmigung durch eine institutionelle Prüfungskommission ist eine Voraussetzung für Studien mit menschlichen Probanden. Sie gewährleistet den Schutz der Probanden und ist oft für die Veröffentlichung von Daten erforderlich. Während die Einholung einer ethischen Genehmigung in den Medizin- und Sportwissenschaften seit Langem gängige Praxis ist, hat ihre Bedeutung erst kürzlich innerhalb der HAR-Gemeinschaft breitere Anerkennung gefunden. Zu den HAR-Datensätzen mit dokumentierter ethischer Genehmigung gehören: *HARTH* [LK23; Log+21], *CAPTURE-24* [Cha+21; Cha+24], *UCA-EHAR* [Nov+21; Nov+22], *MEVA* [Cor+21; Meva25] *HAR70+* [LU23; Ust+23], *OPERAnet* [Boc+22; Boc22], *HA4M* [Cic+22; Mar+22], *Wi-Fi*-Datensatz [Als+20; Als20] und *Smartwatch- und Smartphone*-Datensatz [Mat23; MCG23].

4.3.2 Phase 2 | Vorbereitung der Datenaufnahme

Der nachfolgende Abschnitt des Frameworks umfasst die Schritte 10 bis 15, die sich auf die Vorbereitung der Datenaufnahme beziehen, wobei die Bedeutung der Testaufnahme in Schritt 15 hervorzuheben ist.

10. Probandenakquisition: Eine ausreichende Anzahl von Probanden gewährleistet demografische Variabilität und reduziert Verzerrungen. Eine Überprüfung der HAR-Datensätze ergab einen Durchschnitt von 20 Probanden, wobei die Spanne von 1 bis über 224 reicht [Nie+20a]. Über 65 % der Datensätze umfassen 15 oder weniger Probanden.

11. Probandencharakteristiken: Wie in [Nai+23] dargelegt, wirken sich die Probandencharakteristiken auf die Leistung des neuronalen Netzwerks aus. Eine ausgewogene Verteilung dieser Merkmale verbessert die Modellgenauigkeit [Nai+25], erhöht die Verallgemeinerbarkeit [Nap+24] und reduziert Verzerrungen [Men+24].

Über Alter und Geschlecht [AAA21] hinaus verbessert die Dokumentation der Händigkeit [LK23; Log+21], Körpergröße und -masse [Mar+25], berufliche Qualifikationen und aktivitätsbezogene Erfahrung in der Zielaufgabe [Hoe+23a; OpenPack22; Yos+24] die Nützlichkeit und Fairness des Datensatzes. Die Auswahl der Merkmale erfolgt auf der Grundlage des Anwendungsbereichs. Weiterhin sind anwendungsspezifische Merkmale wie körperliche Beeinträchtigungen (z. B. *HAR70+* [LU23; Ust+23] und [Ren+24]), Fitnessniveau (z. B. *PAMAP2* [Rei12; RS12] und *MHEALTH* [Ban+14b; Ore14])

sowie je nach Anwendungsbereich des Datensatzes möglicherweise kultureller Hintergrund oder Sprache zu berücksichtigen. Ein Überblick der zu berücksichtigenden Probandencharakteristiken ist in Tabelle 4.11 aufgeführt.

Tabelle 4.11 Taxonomie der Datensatzerstellung: Probandencharakteristiken

Kategorie	Realisierungsoptionen	
Probanden-charakteristiken	Alter	Geschlecht
	Händigkeit	Körpergröße
	Körpermasse	aktivitätsbezogene Erfahrung
	berufliche Qualifikation	körperliche Beeinträchtigung
	Fitnesslevel	kultureller Hintergrund
	Sprache	andere

12. Aufnahmeprotokoll: Ein strukturiertes Protokoll verbessert die Reproduzierbarkeit und hilft bei der Identifikation von Verfahrensproblemen. Es enthält detaillierte Schritte für den Versuchsaufbau, Anweisungen für die Probanden, Kalibrierungsroutinen und Notfallmaßnahmen. Protokolle sind in allen Sessions einheitlich zu verwenden. Ein Beispiel für ein detailliertes Protokoll ist der *HDM12 Dance*-Datensatz [VK16].

13. Sensorsysteme und 14. Aufnahmeumgebung einrichten: Sensoren sind auf Zuverlässigkeit, Synchronisation, Kalibrierung und Datenqualität sowie auf Datenübertragung zu testen. Die Aufnahmeumgebung wird auf der Grundlage der definierten Szenarien vorbereitet, wobei die ordnungsgemäße Funktion aller technischen Komponenten sicherzustellen ist. Diese Einrichtung ist rechtzeitig im Voraus abzuschließen, um eine Fehlerbehebung vor der Testaufnahme zu ermöglichen.

15. Testaufnahme: Die Testaufnahme, auch Pilotstudie genannt, stellt eine vorläufige Umsetzung der Hauptdatenaufnahme dar [Ara+10]. Sie dient als entscheidender Schritt zur Validierung des Versuchsaufbaus und der technischen Systeme [VH02] sowie zur Identifizierung, Minderung und, im Idealfall, zur Beseitigung sowohl technischer als auch probandenbezogener Störvariablen [Tha+10]. Eine weitere wichtige Funktion der Testaufnahme ist die Schulung des Studienpersonals in der technischen Handhabung, der Durchführung der Verfahren und der Interaktion mit den Probanden

[LDK11]. Sie erfolgt nach dem erfolgreichen Testen der Sensoren und der Einrichtung der Aufnahmeumgebung, jedoch vor Beginn der Hauptdatenaufnahme.

4.3.3 Phase 3 | Durchführung der Datenaufnahme

Nach der Vorbereitungsphase findet die Datenaufnahme in sechs Schritten (16–21) statt.

16. Einwilligungserklärung einholen: Einwilligungserklärungen (siehe Schritt 7) sind vor Beginn der Datenaufnahme zu unterzeichnen. Eine nachträgliche Einholung der Einwilligung wird als ethisch inakzeptabel angesehen [Wor13].

17. Dokumentation: Alle Aspekte des Versuchsaufbaus sind zu dokumentieren. Dazu gehören die Platzierung der Sensoren, der Zeitplan der Aufnahmesession, die Umgebungsbedingungen und etwaige Unregelmäßigkeiten.

18. Sensorkalibrierung: Sensorsysteme, wie oMoCap-Systeme, sind vor der Datenaufnahme zu kalibrieren. Dazu gehören die Kontrolle der Abtastraten, der Positionsgenauigkeit und der Gerätekonnektivität.

19. Sensorsynchronisation: Die Synchronisation richtet verschiedene Datenströme zeitlich aufeinander aus. Sie basiert auf globalen Zeitstempeln, die durch kontrollierte Bewegungen der Probanden entstehen, oder auf anderen visuellen (Licht) und akustischen Signalen [Fai07; Rhe+09; RN10]. Eine Synchronisationsbewegung beinhaltet z. B. das Heben der Arme, das Klatschen mit den Händen oder das Stampfen mit den Füßen. Im Frameworkschritt der Annotation labeln die Annotatoren für jeden Sensortyp den Start- und Endzeitpunkt dieser Synchronisationsbewegung. Eine genaue Synchronisation ist für die Sensorfusion und eine valide Annotation unerlässlich. Zur Gewährleistung einer konsistenten zeitlichen Ausrichtung sind alle Aufnahmen auf eine einheitliche Zeitachse zu resampeln, beispielsweise mithilfe einer stückweisen Spline-Interpolation.

20. Probelauf: Probeläufe helfen den Probanden, sich mit den Aufgaben vertraut zu machen, und verringern Verhaltensschwankungen aufgrund von Unvertrautheit. Sie weisen eine möglichst hohe Übereinstimmung mit dem eigentlichen Aufnahmeverfahren auf. Eine einheitliche Probelaufstruktur für alle Probanden gewährleistet die Vergleichbarkeit.

21. Hauptdatenaufnahme: Während der Hauptdatenaufnahme sind Eingriffe durch das Studienteam auf ein Minimum zu reduzieren und standardisier-

te, konsistente Anweisungen zu verwenden, um ein natürliches Verhalten der Probanden zu gewährleisten. Eine sorgfältige Schulung des Studienpersonals, wie sie im Rahmen der vorbereitenden Testaufnahmen erfolgt (siehe Schritt 15), ist dabei essenziell für die Einhaltung des Aufnahmeprotokolls. Ebenso sind sensorbezogene Aspekte wie die korrekte Platzierung, die Signalqualität und -übertragung, der Batteriestatus sowie die verfügbare Speicherkapazität kontinuierlich zu überwachen.

4.3.4 Phase 4 | Vorbereitung der Datenverarbeitung

Wie in Abbildung 4.8 dargestellt, erfolgen die folgenden Schritte (22–26) der Vorbereitung der Datenverarbeitung parallel zur Vorbereitung und Durchführung der Datenaufnahme.

22. Klassenlabels: Labels stellen symbolische Repräsentationen menschlicher Bewegungen sowie von Kontextinformationen dar. Kontextbezogene Labels sind heterogen und lassen sich nicht vollständig in klar abgegrenzte Einzelkategorien einordnen. Exemplarische **Kategorien** sind in Tabelle 4.12 aufgeführt. Labels menschlicher Bewegungen hingegen werden in zehn übergeordnete Labelkategorien gegliedert (siehe Tabelle 4.13).

Tabelle 4.12 Exemplarische Kontextlabekategorien

Kontextlabelkategorien	Beschreibung
Räumlicher Kontext	Position (Koordinaten), Areal / Zone (Montagebereich, Trainingsbereich), Umgebung (innen, außen)
Prozesskontext	Prozesshierarchien, Prozessschritte, Prozessstatus
Organisatorischer Kontext	Auftragsinformationen (ID, Beschreibung), Ziel der Aktivität, Priorität, Trainingsplan, Produktionslinie
Personenbezogener Kontext	Rolle, Qualifikation, physische Einschränkungen
Objektkontext	verwendete Werkzeuge, Maschinen- und Gerätespezifikationen
Situationskontext	Störungen, Fehler
Zeitlicher Kontext	Tageszeit, Schicht, Aufgabensequenz, zeitliche Vorgaben für Aufgabenerfüllung
Umgebungskontext	Emissionen und Immissionen (Lärm, Licht, Temperatur)
Sozialer Kontext	Alleine / in Gruppe, Anleitung

Die Methode der Annotation bestimmt die zeitliche Granularität der Labelzuweisung. Label werden entsprechend der **Zeitstruktur** gesetzt: *Frameweise Annotation* weist jedem einzelnen Datenpunkt ein Label zu, wird jedoch

Tabelle 4.13 Bewegungslabelkategorien mit Beispiellabeln, basierend auf [Cha23; IKE13; Mor+23; OOA24; VNK15]

Bewegungslabelkategorien	Labelbeispiele
Körperhaltungen / statische Aktivitäten	Sitzen, Stehen, Liegen, Hocken, Knien
Fortbewegung	Gehen, Rennen, Joggen, Sprinten, Schritt
Gesten / feinmotorische Aktivitäten	Winken, Zeigen, Greifen, Tippen, Schreiben, Hände heben
Mensch-Objekt-Interaktion	Tragen, Heben, Schieben, Öffnen, Verpacken, Wegräumen, Ausgießen, Platzieren, Werfen, Falten, Aufschrauben
Aktivitäten des täglichen Lebens (ATL)	Zähneputzen, Waschen, Essen, Trinken, Anziehen, Kochen, Toilettengang, Betten machen, Staubsaugen, Bügeln, Wäsche zusammenlegen, Hausputz, Fernsehen, Medikamente einnehmen, mit dem Hund Gassi gehen, Geschirr spülen
Sport	Tanz, Gymnastik, Akrobatik, Kampfsport, Fußball, Boxen, Laufen, Basketball, American Football, Schwimmen, CrossFit
Gesundheit Ereignisse	Sturz, Ausrutschen, Stolpern, Zusammenbruch, Beinahe-Sturz, Straucheln, Gleichgewichtsverlust, Erstarren, Zögern, Krampfanfall, Zittern, Husten, abnormale Gangart, Ermüdung
Zusammengesetzte/übergeordnete Aktivitäten	Kochen, Büroarbeit, Entspannen, Aufräumen, Tanzen, Yoga, Sandwichzubereitung
Umwelt/Verfahren Kontext	Ort, Prozess, Kommissionierauftrag, Kaffeepause, früher Morgen
Verhalten	Lächeln, Weinen, Wut, Denken

aufgrund ihres hohen Arbeitsaufwands in der Praxis selten verwendet. *Segmentweise Annotation* verwendet flexible Zeiträume, die auf dem natürlichen Beginn und Ende von Aktivitäten und Kontext basieren. Sie ist effizienter als das frameweise Annotieren und erfasst insbesondere Bewegungsübergänge besser. *Fensterweise Annotation* weist festgelegten Zeitfenstern (z. B. 5 Sekunden) Labeln zu. Diese Methode eignet sich gut für die Vorverarbeitung im maschinellen Lernen und für (semi)automatisierte Annotationen, weist jedoch den Nachteil auf, dass innerhalb eines Zeitfensters eine oder mehrere Aktivitäten und Kontextinformationen auftreten.

Weitere Dimensionen sind die **Labelexklusivität** und die **Labelhierarchie**. Bei der *Einzel-Label-Annotation* wird jedem Zeitintervall genau ein Label zugewiesen, was typisch für *flache Labels* ist. Diese bestehen aus einer einstufigen, nicht-hierarchischen Menge einander ausschließender Kategorien. Bei *hierarchischen Labels* wird die *Einzel-Label-Annotation* unabhängig innerhalb jeder

Ebene angewendet, wobei die Labels innerhalb der jeweiligen Annotationsebene einander ausschließen. Treten mehrere Aktivitäten gleichzeitig auf, ist eine *Mehrfach-Label-Annotation* erforderlich, bei der Labels auch gewichtet werden. In solchen Fällen sind *hierarchische Labels* vorteilhaft, da sie verschiedene Labelkategorien über mehrere Ebenen hinweg abbilden, jedoch mit erhöhtem Annotationsaufwand einhergehen.

Labelsicherheit: In der Regel stützt sich die Annotation auf *harte Labels*, d. h. definitive Kategorieneinteilungen (z. B. „100 % Schritt“). Bei Unsicherheit werden jedoch *probabilistische Bezeichnungen* verwendet, die Wahrscheinlichkeiten angeben (z. B. „80 % Schritt“ und „20 % Stehen“), oder *mit Konfidenz annotierte Labels*, die die Sicherheit des Annotators widerspiegeln (z. B. „Schritt (hohe Sicherheit)“). Die Taxonomie der Labels ist in Tabelle 4.14 dargestellt.

Tabelle 4.14 Taxonomie der Datensatzerstellung: Labelstruktur

Label-Struktur	Realisierungsoptionen	
Label-Kategorien	Körperhaltungen / statische Aktivitäten	Fortbewegung
	Gesten / Feinmotorik-Aktivitäten	Mensch-Objekt-Interaktion
	Aktivitäten des täglichen Lebens	Sport
	zusammengesetzte Aktivitäten	Gesundheit
	Umwelt-/Verfahrenskontext	Verhalten
Label-Zeitstruktur	frameweise Annotation	segmentweise Annotation
	fensterweise Annotation	
Exklusivität von Labels	Einzel-Label	Mehrfach-Labels
Label-Hierarchie	flache Labels	hierarchische Labels
Label-Sicherheit / -Unsicherheit	harte Labels	probabilistische Labels
	mit Konfidenz annotierte Labels	

23. Labelabhängigkeiten: Abhängigkeiten definieren zulässige und unzulässige Kombinationen von Labels innerhalb von Annotationsschemata. Beispielsweise kann ein Proband zu einem Zeitpunkt nicht gleichzeitig die

Aktivitäten *Gehen* und *Stillstehen* ausführen. Solche Abhängigkeiten bestehen sowohl innerhalb einzelner Klassenkategorien, die als Annotationsebenen interpretiert werden (z. B. Aktivität), als auch kategorieübergreifend, etwa zwischen Aktivität, Ort und Prozess. Beispielsweise ist der Prozess *Braten*, mit der Aktivität *Pfanne halten* nur dann zulässig, wenn sich der Proband in der *Küche* befindet; eine Kombination mit dem Ort *Badezimmer* wäre entsprechend ungültig.

Derartige Labelabhängigkeiten lassen sich bereits vor Beginn der Annotation in ein Annotationstool integrieren, etwa durch die explizite Definition zulässiger oder unzulässiger Labelkombinationen. Eine solche Integration reduziert fehlerhafte Labelzuweisungen, erhöht die Konsistenz über alle Annotationen hinweg und beschleunigt den Annotationsprozess, indem während der Annotation ungültige Labels ausgeblendet werden.

24. Annotationsmethode: Die Annotationsmethode lässt sich in Automatisierungsgrad der Annotation, Annotatorenerfahrung und Annotationsanzahl je Aufnahme unterteilen (siehe Tabelle 4.15).

Der **Automatisierungsgrad der Annotation** lässt sich in *manuelle*, *vollautomatische*, *semiautomatische*, *sensorfusionsbasierte* und *crowdsourced* Methoden [Dem+23] unterteilen. Jede Methode hat Vor- und Nachteile in Bezug auf Qualität und Effizienz. Manuelle Methoden gewährleisten Genauigkeit, während hybride oder automatische Techniken Skalierbarkeit bei reduziertem Überwachungsaufwand bieten.

Annotatoren und Revisoren sind zu rekrutieren und zu schulen; dazu gehören *Experten des Anwendungsbereichs* (z. B. Ärzte, Sportwissenschaftler oder Tänzer), *geschulte interne Annotatoren* (z. B. Forschungsassistenten oder Projektteammitglieder), *Probanden* (z. B. *ETRI* [Chu+22; ETRI21]) oder *Laien* (z. B. Community-Mitwirkende oder Crowdworker).

Die Annotationsmethode variiert in Abhängigkeit von der **Annotationsanzahl je Aufnahme**; ausschlaggebend ist dabei, wie häufig eine Aufnahme annotiert wird. Bei der *Einzelannotation* wird eine Aufnahme von genau einer Person annotiert, was eine anschließende Revision erfordert, um die Qualität der Annotation sicherzustellen. Bei der *Mehrfachannotation* annotieren zwei oder mehr Annotatoren dieselbe Aufnahme unabhängig voneinander, wodurch die Konsistenz bewertet wird. Bei der *Konsensannotation* besprechen zwei oder mehr Annotatoren gemeinsam eine Aufnahme, um sich auf eine einheitliche Annotation zu einigen.

25. Annotationstool: Annotation bezeichnet das Hinzufügen von Metadaten oder Beschreibungen zu Daten, wie Kontextinformationen, Objektlabels oder Aktivitätslabels in Bewegungszeitreihen [Nie+20a; Ray23]. Annotationstools unterstützen diesen Prozess durch geeignete Visualisierungen und Hilfsmittel, z. B. zur Bestimmung von Aktivitätsgrenzen, zur synchronen

Tabelle 4.15 Taxonomie der Datensatzerstellung: Annotationsmethoden

Kategorie	Realisierungsoptionen	
Automatisierungsgrad der Annotation	manuell	semi-automatisch
	vollautomatisiert	sensorfusionsbasiert
	durch Crowdsourcing	
Annotatoren-erfahrung	Experte des Anwendungsbereichs	geschulter interner Annotator
	Proband	Laie
Annotationsanzahl je Aufnahme	Einzelannotation durch einen Annotator	Mehrfachannotation durch mehrere Annotatoren
	Einzelannotation durch mehrere Annotatoren	

Darstellung multimodaler und paralleler Sensordatenströme sowie zur Integration von Labelabhängigkeiten (siehe Schritt 23). Die Wahl des Tools richtet sich nach den Visualisierungsanforderungen sowie dem gewünschten Annotationsformat (z. B. JSON, CSV, TEXT). Etablierte Annotationstools wie in Tabelle 4.16 aufgeführt sind aus zeitlichen Gründen zu bevorzugen, auch wenn möglicherweise Anpassungen erforderlich sind.

Tabelle 4.16 Funktionsübersicht von verfügbaren Annotationstools [Moy+26]

Annotationstool		Annotierte Medien			Zugänglichkeit			Zusätzliche Funktionen		
Name	Ref.	Video	oMoCap	Andere	Plattform	Offen	Update	Semi.	Syn.	Analyse
Advene	[AP05]	X	-	-	BS	X	2023	X	X	-
ANVIL	[Anvil14; Kip14]	X	X	Audio	BS	-	2017	-	X	X
ELAN	[BR04; Wit+06; YKK18]	X	-	Audio	BS	X	2023	-	X	-
MaD GUI	[Oll+22]	-	-	OBD	BS	X	2023	X	X	X
NOVA	[Bau+20]	X	X	-	BS	X	2023	X	-	X
SARA	[Nie+23]	X	X	-	BS	X	2022	X	X	-
SDAT-mSAR	[DSS17]	X	-	-	Web	-	-	X	X	X
Signalinger Pro	[Pon+21; Signal17]	-	-	IMU	Beide	X	2021	X	-	-
SPHERE	[Ton+18; Woz+17]	-	-	NFC	App	-	2018	-	-	-
WDK	[ave19]	-	-	OBD	BS	X	2020	X	X	X

Anmerkung: BS = Betriebssystem, Beide = webbasierte und native Anwendung, Semi. = semiautomatische Annotation, Syn. = Synchronisation, NFC = Near Field Communication, OBD = On-Board-Diagnose; X = zutreffend, - = nicht zutreffend

26. Annotationsrichtlinien und Schulung: Die Schulung von Annotatoren und Revisoren mittels Annotationsrichtlinien und anderer Medien gewährleistet Konsistenz und reduziert Subjektivität im Annotationsprozess [Dem+23]. Dadurch, dass alle Annotatoren dieselben Kriterien befolgen, wird

die Interrater-Reliabilität verbessert. Klare und gründliche Anweisungen verkürzen außerdem die Einarbeitungszeit und minimieren den Klärungsbedarf neuer Annotatoren. Weiterhin verbessern gut dokumentierte Richtlinien die Reproduzierbarkeit. Sie enthalten Definitionen von Labels, Anweisungen zur Verwendung der Tools und Beispiele für Sonderfälle. Erfahrungen haben gezeigt, dass eine Ergänzung schriftlicher Materialien durch Videos oder kommentierte Annotationsbeispiele das Verständnis über die Labels verbessert [Nie+20c; Nie+21b].

4.3.5 Phase 5 | Durchführung der Datenverarbeitung

Nach der Erfassung der Daten werden diese exportiert und für die Annotation und Revision vorbereitet (Schritte 27–30). Die letzten Schritte des Datenverarbeitungsprozesses umfassen die Qualitätskontrollen der Sensordaten 31 und der Labels 32.

27. Datenexport und -kontrolle: Der Export von Daten in weitverbreiteten Formaten (z. B. CSV, BVH) gewährleistet langfristige Verwendbarkeit und Kompatibilität. Proprietäre Formate, für die spezielle Tools erforderlich sind, gilt es zu vermeiden. Beispielsweise sind die Vicon-Exporte aus *LARa* [Nie+20c] nicht mit anderer Software als Vicon kompatibel. Ein ähnlicher Fall liegt beim *OpenPack*-Datensatz [OpenPack22; Yos+24] vor, der ursprünglich ein proprietäres Format verwendete, welches nicht ohne Weiteres zugänglich war.

28. Datenaufbereitung: Dateien sind einheitlich zu benennen und zu organisieren, z. B. nach Proband, Aufnahmesession, Szenario usw. Dies ist für eine effiziente Datenverarbeitung unerlässlich. Eine ordnungsgemäße Dateiverwaltung unterstützt die Reproduzierbarkeit und reduziert Fehler bei der Analyse. Die Struktur ist mit dem gesamten Datenaufnahmeprotokoll abzustimmen.

29. Annotation: In diesem Schritt wird die Annotation gemäß den zuvor definierten Labels (Schritt 22), der ausgewählten Annotationsmethode (Schritt 24), dem Annotationstool (Schritt 25) und den Annotationsrichtlinien (Schritt 26) durchgeführt. Zur Sicherstellung der Labelqualität führen entweder alle Annotatoren standardisierte Testannotationen durch oder jede Aufnahme erfolgt durch mindestens zwei Personen (Mehrfachannotation). Während der Annotation sind die Verantwortlichkeiten klar zuzuweisen und regelmäßige Stichprobenkontrollen durchzuführen. Diese erfolgen automatisiert (z. B. Überprüfung auf Labellücken) oder manuell (z. B. Überprüfung einzelner Annotationssequenzen). Große Projekte profitieren von strukturier-

ten Arbeitsabläufen und cloudbasierter Zusammenarbeit.

30. Revision: Die Revision dient der Sicherstellung der Annotationsqualität, indem Konsistenz, Genauigkeit und Vollständigkeit überprüft werden, insbesondere bei Einzelannotation durch einen Annotator. Gängige Revisionsmethoden umfassen die *manuelle Prüfung*, *automatisierte Plausibilitätsprüfungen* und den *Vergleich mehrerer Annotationen* (siehe Tabelle 4.17).

Automatisierte Plausibilitätsprüfungen beinhalten unter anderem die Erkennung von Labellücken und unplausiblen Labelsequenzen, beispielsweise wenn auf eine sitzende Haltung unmittelbar das Schieben eines Kommissionierwagens folgt, ohne dass zuvor das Greifen des Wagens annotiert wurde. Bei hierarchischen Labels lassen sich solche Inkonsistenzen nicht nur über Zeitintervalle, sondern auch punktuell auf Frameebene identifizieren. Je stärker die Korrelation der Klassenkategorien innerhalb der Hierarchie ist, desto mehr automatisierte Plausibilitätsprüfungen lassen sich implementieren. So weist etwa die gleichzeitige Annotation der Labels *Gehen* und *starke Torsobeugung* in einem Frame auf einen Fehler hin, da das parallele Auftreten beider Bewegungen biomechanisch unwahrscheinlich ist. Solche Prüfungen erfolgen sowohl während des Annotationsprozesses als auch im Rahmen der abschließenden Revision, verbessern die Annotationsqualität und erfordern nur geringen zusätzlichen Zeitaufwand.

Der Vergleich mehrerer Annotationen wird typischerweise in Szenarien mit mehreren Annotatoren angewendet. Dabei wird für jedes Frame, Segment oder Zeitfenster das am häufigsten vergebene Label automatisch oder manuell, etwa mittels Mehrheitsentscheidung, bestimmt.

Tabelle 4.17 Taxonomie der Datensatzerstellung: Revisionsmethoden

Kategorie	Realisierungsoptionen	
Revisionsmethoden	manuelle Prüfung	automatische Plausibilitätsprüfungen
	Vergleich mehrerer Annotationen	

31. Sensordatenqualität: Die Sensoraufnahmen sind auf Fehler wie Aussetzer, Rauschen oder Geräteausfälle zu überprüfen. Betroffene Segmente sind je nach Fehlerart zu korrigieren, von dem Datensatz auszuschließen oder mittels eines geeigneten Labels zu kennzeichnen.

32. Labelqualität: Die Durchführung von Konsistenzprüfungen ist für manuelle Annotationen notwendig. Sie hilft dabei, mehrdeutige Label oder annotatorspezifische Verzerrungen zu identifizieren. Dies verbessert die Zuverlässigkeit der Labels und die Ergebnisse des Modelltrainings. Die Konsistenz der Labels wird anhand von Metriken wie dem κ-Koeffizienten

bewertet. Im Gegensatz zu Leistungskennzahlen wie Genauigkeit oder F1-Maß, die eine Annotation als Grundwahrheit (ground truth) behandeln, konzentriert sich Cohen's-κ auf die Messung der Übereinstimmung über den Zufall hinaus [Coh60]. Cohen's-κ ist definiert als

$$\kappa_{A_a,A_b} = \frac{Pr(a)_{A_a,A_b} - Pr(e)_{A_a,A_b}}{1 - Pr(e)_{A_a,A_b}}, \tag{4.1}$$

wobei $Pr(a)$ die beobachtete Übereinstimmung zwischen zwei Annotationsläufen bezeichnet. Diese wird berechnet als die Anzahl der Proben, bei denen beide Annotatoren übereinstimmten, geteilt durch die Gesamtzahl der Proben (auch als Genauigkeit bezeichnet). Die erwartete zufällige Übereinstimmung, $Pr(e)$, wird wie folgt berechnet:

$$Pr(e)_{A_a,A_b} = \frac{1}{M^2} \sum_{C} A_a^c A_b^c, \tag{4.2}$$

wobei M die Gesamtzahl der Stichproben ist, C die Aktivitätsklassen oder Attribute darstellt und A_a^c die Häufigkeit angibt, mit der der Annotator a die Klasse c gekennzeichnet hat.

Wenn mehr als zwei Annotationsläufe vorliegen, wird Light's-κ berechnet [Lig71]. Light's-κ ist das arithmetische Mittel aller paarweisen Cohen-κ. Light's-κ ist definiert als

$$\kappa_{\text{Light}} = \frac{2}{N(N-1)} \sum_{i=1}^{N-1} \sum_{j=i+1}^{N} \kappa_{ij}, \tag{4.3}$$

wobei N die Anzahl der Annotatoren sind und κ_{ij} den Cohen's-κ-Wert zwischen den Annotatoren i und j angibt.

Zur einheitlichen Benennung der relativen Übereinstimmungsstärke in Verbindung mit κ-Werten existieren verschiedene Skalen, die in Abbildung 4.9 dargestellt sind. Diese Einteilungen basieren auf subjektiven Einschätzungen der jeweiligen Autoren, liefern jedoch einen Orientierungsrahmen bei der Interpretation der Labelqualität [Cza94; Foo20].

Die Qualität der annotierten Labels in Kombination mit Sensordaten wird indirekt über die Leistung trainierter Klassifikatoren bewertet und dient damit als Maß für die Güte der eingesetzten KI-Methoden. Hierfür werden unter anderem Precision-, Recall- und F1-Maß herangezogen.

Die Precision ist definiert als $P = \frac{TP}{TP+FP}$, der Recall als $R = \frac{TP}{TP+FN}$, wobei TP, FP und FN die Anzahl der wahren Positiven, falschen Positiven bzw. falschen Negativen bezeichnen. Der gewichtete F1-Maß ergibt sich zu

$$wF1 = \sum_{i}^{C} 2 \times \frac{n_i}{N} \times \frac{P_i \times R_i}{P_i + R_i}, \tag{4.4}$$

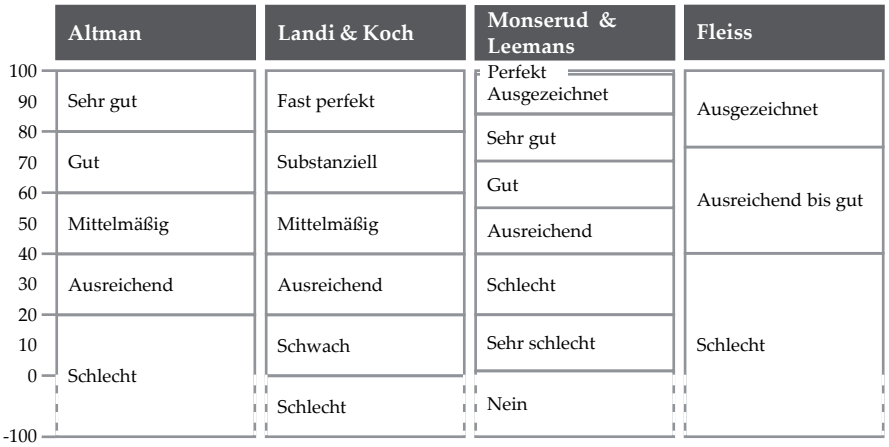


Abb. 4.9 Skalen zur Interpretation des Kappa-Koeffizienten nach [Alt90; Fle73; LK77; ML92] und modifiziert sowie aktualisiert auf Basis von [Cza94; Foo20]

wobei n_i die Anzahl der Fenstersamples der Klasse $C_i \in C$ und N die Gesamtzahl aller Samples ist.

4.3.6 Phase 6 | Veröffentlichung des Datensatzes

In der letzten Phase des Frameworks werden die Daten, vorhandene Skripte und die Datenbeschreibung veröffentlicht (Schritte 33–36).

33. Datenveröffentlichung: Gemäß den FAIR-Prinzipien [Wil+16] und FORCE11-Prinzipien [DM14] sind Datensätze über Repositorien mit persistenten Identifikatoren (z. B. Digital Object Identifier (DOI)) zu veröffentlichen, um ihre Auffindbarkeit und langfristige Zugänglichkeit sicherzustellen. Alle Materialien – Sensordaten, Anmerkungen und Dokumentationen – sind in standardisierten, maschinenlesbaren Formaten mit klaren Lizenzen und Metadaten bereitzustellen, um die Wiederverwendung zu unterstützen [ABG22].

34. Klarheit der Datenstruktur: Ein organisierter Datensatz mit konsistenter Namenskonvention, klaren Ordnerhierarchien und synchronisierten Datenströmen verbessert die Benutzerfreundlichkeit. Eine klare Datenstruktur umfasst zudem Metadaten zu Zeit, Probanden, Sensoren, Sensorplatzierung und Labels.

Ein Beispiel, das diese Prinzipien befolgt, ist der *PAMAP2*-Datensatz [Rei12]. Die Aufnahmen jedes Probanden sind in einer einzigen Datei enthalten, was die Navigation und den Zugriff vereinfacht. Die Dateien enthalten synchronisierte Multisensordaten. Weiterhin liefert *PAMAP2* detaillierte Metadaten zu jedem Probanden. Aktivitätsbezeichnungen sind klar in jede Aufnahme eingebettet, und fehlende Werte sind mit NaN gekennzeichnet,

was eine unkomplizierte Vorverarbeitung unterstützt.

35. Vorverarbeitungsskript: Vorverarbeitungsskripte unterstützen Nutzer bei der Überführung von Rohdaten in eine analysefähige Form. Sie decken grundlegende Schritte wie Synchronisierung, Segmentierung, Normalisierung sowie den Umgang mit fehlenden Werten ab, sind entsprechend zu dokumentieren und enthalten Konfigurationsdateien. Dass 67,7 % der befragten Nutzer eine Vorverarbeitung benötigen [Ala+23], unterstreicht den Mehrwert der Bereitstellung entsprechender Skripte.

Überdies erhöhen Beispielskripte für den Datenzugriff, die Visualisierung und die Implementierung eines Basismodells die Benutzerfreundlichkeit. Sie erleichtern das Verständnis der Datenstruktur, der Synchronisation sowie des Umgangs mit fehlenden Werten [Dam+22; Yos+24].

36. Datenbeschreibung veröffentlichen: Klare und strukturierte Datensatzbeschreibungen sind entscheidend für Transparenz, Interpretierbarkeit und Wiederverwendbarkeit. Gebru et al. [Geb+21] schlagen Datenblätter vor, um Kontext, Inhalt und Verwendungszweck zu dokumentieren. Mangelhafte Metadaten behindern oft die Wiederverwendbarkeit [ABG22].

Die Beschreibungen sind frei zugänglich in englischer Sprache (idealerweise mit DOI) zu veröffentlichen und enthalten technische Details zu Sensorkonfiguration, Datenaufnahmemethoden, Hardware und Software. Für HAR-Datensätze sind zudem Informationen zu Demografie und Physiologie der Probanden, zur Labelstruktur, zu Annotationsverfahren und -qualität (einschließlich Kriterien, Methoden, Übereinstimmungsmetriken) sowie zur Qualität der Sensordaten bereitzustellen.

4.3.7 Checkliste

Aus den sechs Phasen des Frameworks und dessen 36 Schritten wurde eine Checkliste für die Erstellung von HAR-Datensätzen abgeleitet (siehe Tabelle 4.18). Ziel ihrer Entwicklung ist es, ein Werkzeug bereitzustellen, das die Datensatzerstellung für HAR erleichtert. Fehler oder Auslassungen wichtiger Kriterien werden damit frühzeitig erkannt und ausgeschlossen, um einerseits eine hohe Qualität des resultierenden Datensatzes und andererseits die Reproduzierbarkeit zu gewährleisten.

Tabelle 4.18 Checkliste für die Datensatzerstellung. Einzelne Nummern sind mehrmals aufgeführt, da für diese Schritte des Frameworks mehrere Kriterien berücksichtigt werden (z. B. hat Schritt 11 sechs Kriterien: 11_a–11_f).

Checkliste für jeden Schritt des Frameworks	
Planung der Datensatzerstellung	
1	Definieren Sie den *Nutzen* und den *Zweck* des Datensatzes.
2	Legen Sie vor Beginn den *Umfang* (Länge und Menge) der Aufnahme fest.

Tabellenfortsetzung Checkliste für jeden Schritt des Frameworks	
3	Bestimmen Sie die *Aufnahmeumgebung*.
4	Definieren Sie die *Szenarien* klar.
5	Wählen Sie die zu verwendenden *Sensoren* (Typ, Anzahl, Positionierung) aus.
6	Erstellen Sie eine *Probandeninformation* zur der Studie, den Aufnahmen und der Verwendung der Daten.
7	Bereiten Sie eine *Probandeneinwilligungserklärung* für die Probanden vor.
8	Erstellen Sie einen *Fragebogen*, um personenbezogene Daten (z. B. Alter, Gewicht) von den Probanden zu erfassen.
9	Holen Sie ein positives *Ethikvotum* für die geplante Studie/Aufnahme ein.
Vorbereitung der Datenaufnahme	
10_a	Akquirieren Sie *genügend Probanden*, um die demografische Variabilität in dem Anwendungsbereich widerzuspiegeln.
10_b	Akquirieren Sie *Ersatzprobanden*, die nicht zum Studienteam gehören.
10_c	Senden Sie allen Probanden einige Tage vor der Aufnahme die *Probandeninformation*, den *Fragebogen* und die *Probandeneinwilligungserklärung* zu.
11_a	Stellen Sie sicher, dass die *Altersverteilung* der *Zielgruppe* entspricht.
11_b	Stellen Sie sicher, dass die *Geschlechterverteilung* der *Zielgruppe* entspricht.
11_c	Stellen Sie sicher, dass die *Händigkeit* innerhalb der *Zielgruppe* ausgewogen ist.
11_d	Stellen Sie sicher, dass die *beruflichen Qualifikationen* die *Zielgruppe* widerspiegeln.
11_e	Stellen Sie sicher, dass die *aktivitätsbezogene Erfahrung* die *Zielgruppe* widerspiegelt.
11_f	Stellen Sie sicher, dass *Körpergröße* und *Körpermasse* repräsentativ für die *Zielgruppe* sind.
12	Erstellen Sie *Aufnahmeprotokolle* zur Dokumentation (z. B. Zuordnung von Probanden-IDs zu Sensor-IDs, Beginn der Sessions, Störungen, Platzierung der Sensoren).
13	Beschaffen und testen Sie die *Sensorsysteme*.
14	Richten Sie die *Aufnahmeumgebung* ein.
15	Führen Sie vor der Hauptaufnahme *Testaufnahmen* durch, um die Aufnahmepipeline zu validieren.
Durchführung der Datenaufnahme	
16	Stellen Sie sicher, dass alle Probanden vor der Aufnahme die *Probandeneinwilligungserklärung* unterzeichnet haben.
17_a	Führen Sie das *Protokoll* vor, während und nach der Datenaufnahme.
17_b	Stellen Sie sicher, dass alle Probanden den *Fragebogen* ausgefüllt haben.
18	Führen Sie eine *Kalibrierung* durch, um Messfehler zu minimieren.
19	Stellen Sie die *Synchronisation* aller Sensoren im Falle eines Multisensor Datensatzes sicher.
20	Führen Sie mit jedem Probanden *Probeläufe* durch.
21_a	*Minimieren Sie Eingriffe* durch das Aufnahmeteam, um ein natürliches Verhalten der Probanden zu ermöglichen.
21_b	*Überprüfen* Sie regelmäßig, ob alle *Sensoren* während und zwischen den Aufnahmesession korrekt aufzeichnen.
Vorbereitung der Datenverarbeitung	
22	Definieren Sie die *Klassenlabels* klar und eindeutig.
23	Definieren Sie *Abhängigkeiten* zwischen Klassenlabels (z. B. schließen sich „Stehen" und „Gangzyklus" als gleichzeitige Labels aus).
24	Akquirieren Sie *Annotatoren* und *Revisoren*.
25	Wählen Sie ein *Annotationstool* aus und testen Sie es.
26_a	Erstellen Sie klare *Annotationsrichtlinien*.
26_b	Arbeiten Sie *Annotatoren* und *Revisoren* ein.
Durchführung der Datenverarbeitung	
27	*Exportieren*, formatieren und kontrollieren Sie die *Sensordaten*.
28_a	*Synchronisieren* Sie alle *Sensordaten*.
28_b	*Benennen Sie die Sensordaten* anhand des Probanden, der Aufnahmesession, des Szenarios und/oder der Aufnahmenummer.
29_a	Führen Sie *Testannotationen* mit Annotatoren und Revisoren durch, um die Qualität der Labels zu ermitteln.

Tabellenfortsetzung Checkliste für jeden Schritt des Frameworks	
29_b	Führen Sie während der Annotation regelmäßig *Stichproben (Qualitätskontrolle) der Arbeit jedes Annotators* durch.
29_c	Stellen Sie sicher, dass die Sensordaten *vollständig gelabelt* sind.
30	Führen Sie eine *Revision aller Annotationen* mit wenige Experten durch.
31_a	Korrigieren oder dokumentieren Sie *Fehler* und *Abweichungen* in den Daten (asynchrone Daten, fehlende Daten).
31_b	Korrigieren Sie *Labelungleichgewicht* im Datensatz.
31_c	Führen Sie eine *Qualitätskontrolle* der *Sensordaten* durch.
32	Stellen Sie sicher, dass die *Labelqualität* ausreichend ist.
Veröffentlichung des Datensatzes	
33_a	Veröffentlichen Sie die **Daten** in einem *Repository* mit einer global eindeutigen und dauerhaften *Kennung* (z. B. DOI).
33_b	Stellen Sie sicher, dass die *Daten offen* und *kostenlos zugänglich* sind.
33_c	Stellen Sie *Sensordaten* und *Labels* in einem formalen, zugänglichen und *weit verbreiteten Format* (z. B. CSV) bereit.
33_d	Stellen Sie sicher, dass alle *Dateibezeichnungen*, *Labels* und *Metainformationen auf Englisch* sind.
33_e	Geben Sie die Daten mit einer *Nutzungslizenz* an.
33_f	Verknüpfen Sie die Daten mit ihren *Herkunftsinformationen* (Land, Stadt, Organisation).
33_g	Fügen Sie *Referenzen* auf die Datenbeschreibung, das Framework, in dem der Datensatz erstellt wurde, und verwandte Datensätze hinzu.
33_h	*Registrieren* oder *indizieren Sie die Daten*, damit sie leicht auffindbar sind.
34_a	Stellen Sie sicher, dass die *Sensordaten* nach Möglichkeit *synchron* sind.
34_b	Stellen Sie sicher, dass alle *Sensordaten gelabelt* sind.
34_c	Fügen Sie ein *Skriptbeispiel* hinzu, das zeigt, *wie die Daten verwendet werden könnten*.
34_d	Stellen Sie sicher, dass das *Annotationstool* in einem *Repository* verfügbar ist.
35	Veröffentlichen Sie ein *Vorverarbeitungsskript*.
36_a	Veröffentlichen Sie eine **Datensatzbeschreibung** in *englischer Sprache*.
36_b	Veröffentlichen Sie eine *Datensatzbeschreibung* in einem *Repository*.
36_c	Veröffentlichen Sie eine *Datensatzbeschreibung* in einer *frei zugänglichen Publikation* mit einer dauerhaften *Kennung* (z. B. DOI).
36_d	Stellen Sie sicher, dass die *Datensatzbeschreibung offen* und *kostenlos zugänglich* ist.
36_e	Beschreiben Sie die *Sensorkonfiguration*.
36_f	Beschreiben Sie die *Datenaufnahmepipeline*.
36_g	Beschreiben Sie die *Probandencharakteristiken* (z. B. Alter, Qualifikationen, Körpergröße).
36_h	Beschreiben Sie die *Labels* im Detail.
36_i	Dokumentieren Sie den *Annotations-* und *Revisionsprozess*.
36_j	Dokumentieren Sie die *Ergebnisse* der *Annotationen* und *Revisionen*.
36_k	Beschreiben Sie die *Qualität* der *revidierten Labels*.
36_l	Beschreiben Sie die *Qualität* der *Sensordaten*.
36_m	Fügen Sie die *Datenkennung in die Beschreibung ein*.

Kapitel 5
Empirischer Beitrag zur aktivitäts- und kontextsensitiven Prozesserkennung

Zusammenfassung Das fünfte Kapitel stellt den intralogistischen DaRA-Datensatz als empirische Grundlage der Arbeit vor. Bestehende Datensätze der Aktivitätserkennung enthalten überwiegend Bewegungsdaten und Aktivitätslabels, erlauben jedoch keine Einordnung zu Arbeitsprozessen. DaRA ergänzt Aktivitätslabels systematisch um Kontextinformationen, insbesondere Lokalisierungs- und Prozesslabels. Dadurch lassen sich erkannte Aktivitäten konkreten Arbeitsschritten innerhalb eines Arbeitsprozesses zuordnen. Der Datensatz schafft somit die empirische Voraussetzung zur Untersuchung prozessorientierter Fragestellungen der Aktivitätserkennung und dient als Grundlage für die Evaluation des entwickelten Prozesserkennungsverfahrens. Die Auswertung der annotierten Klassenlabels zeigt, dass bereits die Kombination von Hauptaktivitäten und Lokalisierungsinformationen einzelne Prozessschritte beschreibt und damit als Basis für eine automatisierte Prozesserkennung dient.

Dieses Kapitel basiert teilweise auf den folgenden Veröffentlichungen:

Friedrich Niemann u. a. „DaRA Dataset: Combining Wearable Sensors, Location Tracking, and Process Knowledge for Enhanced Human Activity and Human Context Recognition in Warehousing“. In: *Sensors* (2026). DOI: 10.3390/s26020739

Friedrich Niemann u. a. *Data Fusion for advanced Research in industrial Applications (DaRA) – A Multi-Sensor, Multi-Level Annotated Dataset for Human Activity and Human Context Recognition in Warehousing*. 2026. DOI: 10.5281/ZENODO.10468175

Friedrich Niemann u. a. *Test Annotations for Quality Evaluation of the DaRA Dataset – Annotated and Revised Video Data with Activity and Context Labels*. 2026. DOI: 10.5281/ZENODO.15118021

Fernando Moya Rueda u. a. „Activity- and Context-Sensitive Recognition of Human-Centered Processes in Warehousing“. In: *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2026)*. Status: eingereicht. Italien, 2026

5.1 Erstellung des DaRA-Datensatzes

Zur systematischen Untersuchung der aktivitäts- und kontextsensitiven Prozesserkennung wurde der *Data Fusion for advanced Research in industrial Applications (DaRA)*-Datensatz [Nie+26a; Nie+26b] erstellt. DaRA bildet intralogistische Prozesse menschenzentriert in einer Laborumgebung ab (siehe Abbildung 5.1). Die Datensatzerstellung erfolgte unter Anwendung des entwickelnden Frameworks (siehe Abbildung 4.8) sowie der daraus abgeleiteten Checkliste (siehe Tabelle 4.18). Die Aufnahme und Annotation des räumlichen Kontexts orientieren sich an den Erkenntnissen der explorativen Studie aus Abschnitt 4.1 und den Anforderungen des entwickelten Prozesserkennungsverfahrens aus Abschnitt 4.2. Die folgenden Abschnitte beschreiben die Datensatzerstellung in Anlehnung an die sechs Phasen und 36 Schritte des Frameworks zur Datensatzerstellung.



Abb. 5.1 Logo des DaRA-Datensatzes. Im Mittelpunkt des Datensatzes und des Logos steht der Mensch, der Objekte im Lager handhabt und transportiert.

5.1.1 Phase 1 | Planung der Datensatzerstellung

Schritt 1 und 2: Zweck des Datensatzes und Aufnahmeumfang

Der DaRA-Datensatz konzentriert sich auf Lagerumgebungen und umfasst Szenarien der Kommissionierung, Verpackung, des Auspackens und der Einlagerung. Schlussfolgernd ist er damit dem Anwendungsbereich *Industrie* zuzuordnen (siehe Datensatztaxonomie in Tabelle A.1). DaRA stammt aus einem Industrieprojekt und erweitert den CAARL-Ansatz durch die Integration und Annotation zusätzlicher Kontextdaten, um eine Prozesserkennung auf der Grundlage von Aktivität und Kontextinformationen zu ermöglichen, mit dem übergeordneten Projektziel, die Generierung von Simulationsmodellen aus HAR und kontextsensitiven Eingaben zu automatisieren. Aufgrund der Projektziele und der vorhandenen Mittel für die Datenaufnahme, Annotation und Revision, wurde ein Aufnahmeumfang von drei Tagen mit insgesamt sechs Aufnahmesessions festgelegt.

Schritt 3: Aufnahmeumgebung definieren

Der Versuchsaufbau wurde im *Picking Lab* am Fraunhofer-Institut für Materialfluss und Logistik (IML) eingerichtet. Das Picking Lab ist eine For-

schungsinfrastruktur für anwendungsorientierte Logistikforschung [Elk+24]. Es konzentriert sich auf zentrale Fragen wie Prozessoptimierung, informationstechnische Führung in der Intralogistik, Mensch-Technik-Interaktion und Ergonomie [WMK24]. Das Labor bildet ein Miniaturlager nach (siehe Abbildung 5.2) und wurde speziell für die Bewertung von Technologien und Prozessen in der konventioneller Kommissioniersysteme (siehe Abschnitt 2.1.5) nach dem PzW-Prinzip konzipiert (siehe Abschnitt 2.1.3). Diese Umgebung ermöglicht die Untersuchung sowohl technologischer als auch verfahrenstechnischer Aspekte der Auftragsabwicklung. Sie wird als *teilweise kontrollierte Umgebung* betrachtet, da sie ein realistisches Lager darstellt, das wesentliche technische Merkmale eines industriellen Lagers in einer kontrollierten Laborumgebung nachbildet (siehe Datensatztaxonomie in Tabelle A.1).



Abb. 5.2 Fachbodenregalanlage des Picking Labs am Fraunhofer IML in Dortmund mit acht nummerierten Regalkomplexen

Die standardisierte Laborumgebung besteht aus einer Fachbodenregalanlage mit acht Regalkomplexen in fünf Gassen (siehe Abbildung 5.2). Im Regalkomplex 1 werden kleine Artikel in offenen Lagerbehältern gelagert. Die Regalkomplexe 2 und 3 enthalten hängende und lose Artikel ohne Behälter. Der Regalkomplex 4 verfügt über Durchlaufkanäle für unverpackte Artikel und solche in Kartons. Der Regalkomplex 5 enthält mittelgroße Artikel, während der Komplex 6 hauptsächlich mittelgroße bis sperrige Artikel in grünen und blauen offenen Lagerbehältern lagert. Sperrige und schwere Artikel befinden sich hauptsächlich in den Regalkomplexen 7 und 8.

- kleine Artikel (ab 0,4 g), wie Schrauben, Unterlegscheiben oder Bits
- mittlere Artikel ($>$ 50 bis 800 g), wie Softshelljacken, Krawatten, Handschuhe, Tragebeutel, Poloshirts oder Notizbücher

- große Artikel (bis zu 5.149 g), wie Äxte und Bügelsägen

Die Artikel werden entsprechend ihrer Eigenschaften in Fächern unter Verwendung von Kleinladungsträgern, Sichtbehältern, Kartons, Kleiderstangen mit Kleiderbügeln oder Durchlaufkanälen gelagert. Die Artikelstammdaten sind dem Abschnitt A.1.3 und eine visuelle Dokumentation der Artikel dem Abschnitt A.1.4 zu entnehmen. Zur Identifizierung von Artikeln und Lagerfächern werden Barcodes und QR-Codes verwendet. Das Picking Lab ist mit einem cloudbasierten Warehouse Management System (WMS) ausgestattet, das mit den Systemen zur informationstechnischen Führung der kommissionierenden Personen verbunden ist.

Die Fachbodenregalanlage wird durch einen freien Bereich vor der Regalfront ergänzt (siehe Abbildung 5.3). Diese Kombination ermöglicht die Umsetzung realistischer Szenarien typischer intralogistischer Anwendungen, darunter E-Commerce, Kleinteilekommissionierung, die Handhabung sperriger oder hängender Güter sowie Verpackungsprozesse.

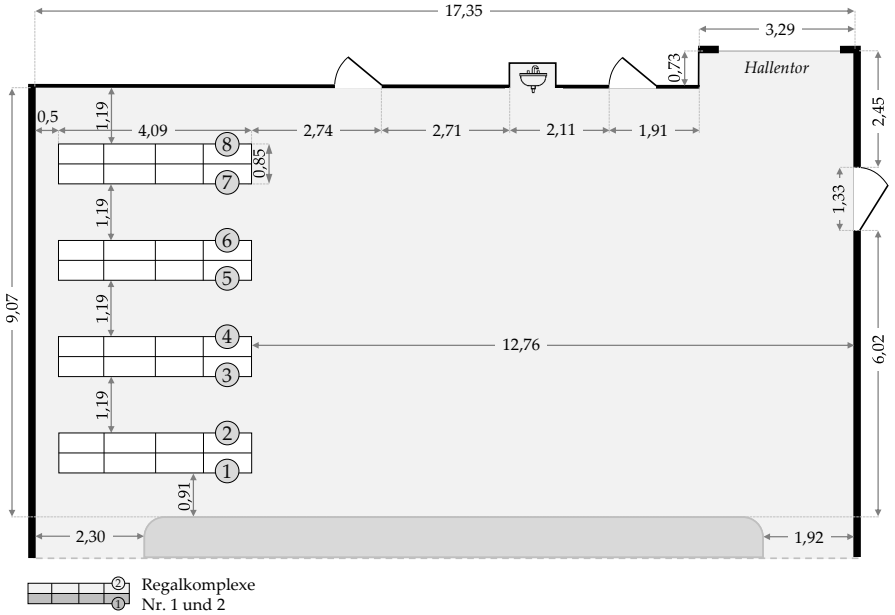


Abb. 5.3 Bemaßter Grundriss des Picking Labs mit acht nummerierten Regalkomplexen auf der linken und dem freien Bereich auf der rechten Seite. Alle Maße in Metern.

Schritt 4: Szenarien definieren

Szenarienübersicht: Insgesamt werden acht Szenarien umgesetzt. Sie unterscheiden sich hinsichtlich des Grobprozesses (Auslagerung vs. Einlagerung), der Kommissionierstrategien, der informationstechnischen Führung, der

Kundenaufträge sowie der geplanten Fehler in den Picklisten. Die Szenarien 1–3 und 7 umfassen die Auslagerung, während die Szenarien 4–6 und 8 den Schwerpunkt auf die Einlagerung legen. Wie in einem industriellen Lager sind die Prozessschritte der Szenarien vordefiniert, die zur Durchführung dieser Schritte erforderlichen Bewegungen jedoch nicht. Dadurch entstehen realitätsnahe Bewegungsabläufe.

Auslagerung (Szenarien 1–3): Die Auslagerungszenarien beginnen mit der Auftragsvorbereitung. Die Probanden erhalten ihre Kommissionieraufträge und Hardware für die informationstechnische Führung im Büro. Anschließend holen sie einen Kommissionierwagen und leere Kartons ab.

Das Kommissionieren beginnt mit dem Transport des Kommissionierwagens zur Basis, wo dieser während des Kommissionierungsprozesses verbleibt. Aufgrund der geringen Gassenbreite ist ein gleichzeitiges Hineinschieben mehrerer Wagen in eine Gasse nicht möglich. Die Artikel werden statisch und dezentral in der Fachbodenregalanlage, geordnet nach deren Eigenschaften wie Maßen und Masse, bereitgestellt und von dort entnommen (siehe Materialflusssystem in Abschnitt 2.1.2). Anschließend werden sie in Kartons auf dem Kommissionierwagen verstaut, was einem Pick & Pack-Ansatz entspricht, bei dem die Artikel direkt in versandfertige Kartons kommissioniert werden.

Abgebildet wird das Prinzip Single Order Picking, wobei jede Kommissionieraufgabe genau einem Kundenauftrag entspricht (siehe Organisationssystem in Abschnitt 2.1.2). Dieses einfache, auftragsorientierte Prinzip erforderte keine weitere Sortierung oder Zusammenführung. Für die Auftragsabwicklung relevante Informationen, wie Lagerfach-ID, Artikel-ID, Artikelbezeichnung und Anzahl der Einheiten, werden den Probanden über informationstechnische Führung (siehe Abbildung 5.4 und Abschnitt 2.1.4) zur Verfügung gestellt:

1. Szenario 1: Pickliste mit Stift
2. Szenario 2: MDE-Gerät
3. Szenario 3: Pickliste mit Handschuhscanner

Die Probanden bewegen sich eindimensional zwischen ihren Wagen in der Basis und den jeweiligen Artikelpositionen in der Fachbodenregalanlage und folgen dabei einer Stichgangstrategie (siehe Wegstrategien in Abschnitt 2.1.6), bei der die Gassen wiederholt vom selben Ende aus betreten und verlassen werden. Für die Szenarien 1–3 werden die Probanden angewiesen, jede Gasse für jede Auftragsposition separat zu betreten, ohne mehrere Positionen gleichzeitig zu bearbeiten (Stichgangstrategie mit Gangwiederholung).

In den Szenarien 2 und 3 führt ein *PbL*-System die Probanden mithilfe optischer Signale an Regalkomplexen und Lagerfächern zu den manuell zu pickenden Artikeln (Einzelstückgut). Während das Licht den Entnahmeort

anzeigt, wird die Anzahl der zu entnehmenden Artikel entweder auf der Pickliste oder auf dem MDE-Gerät angezeigt.

Sobald alle Artikel für einen Auftrag kommissioniert und in die Kartons auf dem Kommissionierwagen gelegt wurden, wird der Kommissionierwagen zu dem Verpackungsort weitertransportiert, wo Verpackungsmaterialien (z. B. Luftpolsterfolie, Versandetiketten, Lieferscheine, Kartonschneider und Klebeband) bereitgestellt werden. Nach dem Verpacken werden die Aufträge abgeschlossen, indem die Kartons zum Warenabgabe- und -annahmebereich transportiert und dort auf Paletten gestellt werden - eine statische, zentrale, ungeordnete Abgabe (siehe Tabelle A.3). Schließlich geben die Probanden ihre Hardware der informationstechnischen Führung zurück.

Jeder Proband wiederholt diese Auslagerung dreimal, wobei er verschiedene Kundenaufträge (Auftrag-IDs: 2904, 2905, 2906 siehe Abschnitt A.1.5) bearbeitet und bei jeder Wiederholung unterschiedliche Hardware für die informationstechnische Führung einsetzt.



(a) Pickliste mit Stift

(b) Mobiles Datenerfassungsgerät

(c) Pickliste mit Handschuhscanner

(d) PbL Signal am Lagerfach

Abb. 5.4 Überblick über die im Picking Lab eingesetzten Systeme zur informationstechnischen Führung während der Kommissionierung

Geplante Fehler beim Kommissionieren mit Picklisten: Um realistische Lagerprozesse widerzuspiegeln, werden in die Szenarien bewusst Störfaktoren

eingebaut. Zu den geplanten Fehlern gehören falsche Lagerorte auf Picklisten (Szenario 1), Mengenabweichungen (Szenario 3), ungeeignete Kartongrößen, Wartezeiten aufgrund begrenzter Verpackungsstationen und fehlende Materialien wie Plastiktüten für Kleinstartikel.

Einlagerung (Szenarien 4–6): Nach den Auslagerungsvorgängen werden in den Szenarien 4–6 Prozesse der Einlagerung durchgeführt. Diese beginnen mit der Auftrags- und Warenannahme. In dieser Phase liegen die ausgelagerten Aufträge dreimal vor, da zuvor jeder Auftrag von jedem der drei Probanden einmal kommissioniert und verpackt wurde.

Für die Einlagerung, werden die gleichen Auslagerungsaufträge zu einem zusammengefasst, sodass insgesamt drei Einlagerungsaufträge vorliegen. Jeder Proband führt daraufhin einen dieser Einlagerungsaufträge aus. Nach dem Transport zum Sortierbereich, werden die Kartons ausgepackt, die Artikel sortiert und anschließend in die Fachbodenregalanlage eingelagert, wobei ausschließlich Picklisten mit Stiften als informationstechnische Führung dienen.

Nach Abschluss der Einlagerung schließen die Probanden ihre Aufträge ab, indem sie die leeren Kartons in den Kartonbereich, ihre Listen und Stifte ins Büro und die Kommissionierwagen im Wagenbereich zurückbringen.

Multi Order Picking (Szenarien 7–8): Die Szenarien 7 (Auslagerung) und 8 (Einlagerung) folgen einem ähnlichen Ablauf wie die vorherigen Szenarien, die Probanden führen jedoch Multi Order Picking aus (siehe Informationsflusssystem in Abschnitt 2.1.2 und Tabelle A.2). Zwei Kundenaufträge (*2904* und *2905*) werden von einem Probanden innerhalb eines einzigen Kommissionierauftrags bearbeitet. Die Artikel werden direkt dem versandfertigen Karton des Kunden zugeordnet, wodurch eine höhere Kommissionierdichte genutzt wird, um die durchschnittliche Wegzeit pro Auftrag zu reduzieren.

Die Probanden wählen in diesen beiden Szenarien ihre Routenstrategien frei und bearbeiten eine oder mehrere aufeinanderfolgende Positionen gleichzeitig, was eine Stichgangstrategie ohne Gangwiederholung ermöglicht (siehe Abschnitt 2.1.6). Weiterhin werden diese Szenarien ohne Unterbrechungen oder Fehler in den Picklisten durchgeführt – sie stellen also einen *optimierten Durchlauf* dar. In den Szenarien 7 und 8 arbeitet nur ein Proband im Picking Lab, um Wartezeiten zu vermeiden. Die Spezifikationen aller acht Szenarien sind in Tabelle 5.1 zusammengefasst.

Die Taxonomie der Szenarien, gegliedert nach Informationsfluss-, Materialflusssystem und Organisationssystem der Kommissionierung aus Abschnitt 2.1.2, ist in den Abbildungen A.2, A.3 und A.4 dargestellt.

Tabelle 5.1 Spezifikation der acht Szenarien

Kategorie	Spezifikation	Szenario							
		1	2	3	4	5	6	7	8
Grobprozesse	Auslagerung (Kommissionieren und Verpacken)	x	x	x				x	
	Einlagerung (Auspacken und Einlagern)				x	x	x		x
Kommissionier-strategien	Single Order Picking (seriell)	x	x	x	x	x	x		
	Multi Order Picking (parallel)							x	x
Informations-technische Führung	Pickliste mit Stift	x			x	x	x	x	x
	Mobiles Datenerfassungsgerät		x						
	Pickliste mit Handschuhscanner			x					
Kunden-auftrag	2904	x			x			x	x
	2905		x			x		x	x
	2906			x			x		
Fehler in der Pickliste	Mit geplanten Fehlern	x		x					
	Ohne geplante Fehler		x		x	x	x	x	x

Schritt 5: Sensoren auswählen

Die Logistikszenarien wurden unter Verwendung mobiler und stationärer Kameras, tragbarer Geräte mit IMUs- und BLE-Received Signal Strength Indicator (RSSI)-Sensoren sowie von Beacon Emitter aufgezeichnet (siehe Abbildung 5.5 und Datensatztaxonomie in Tabelle A.1). Zusätzlich protokollierte ein cloudbasiertes Lagerverwaltungssystem von Logistics Reply die Entnahmen während der Kommissionierung mithilfe eines MDE-Geräts.

Mobile Kameras: Jeder Proband wurde mit einer mobilen GoPro Hero 12 Kamera für FPV ausgestattet (siehe Abbildung 5.5 (a)). Die Kamera wurde an der Stirn befestigt, mit leichter Ausrichtung zu Boden, um nicht nur das Sichtfeld der Probanden, sondern auch die Bewegungen ihrer Arme und Beine aufzunehmen. Aufgrund individueller Anpassungen variierten die Blickwinkel leicht.

Das Ultraweitwinkelobjektiv mit einem Sichtfeld von bis zu 177° deckt ein großes Aufnahmefeld ab (siehe Abbildung 5.6 (a)-(c)). Die FPV-Videos wurden zur Dokumentation verwendet und dienten als primäre Datenquellen für die Annotation und Revision.

Die Befestigung der Kamera an der Stirn erwies sich als die optimale Lösung für eine umfassende Abdeckung des Sichtfeldes und eine annotationsgeeignete Perspektive, insbesondere im Vergleich zur Befestigung an der Schulter oder Brust. Dennoch traten während der Aufnahmen einige Einschränkungen bei der Verwendung auf. Einige Probanden empfanden den Anpressdruck als unangenehm, und bei Probanden mit glattem Haar saß die Kamera nicht immer stabil. Dies führte gelegentlich dazu, dass die



(a) mobile Kamera (GoPro Hero 12) mit Ultraweitwinkelobjektiv und Kopfband



(b) stationäre Kamera (Logitech Mevo) ohne Stativ



(c) tragbares Set der MotionMiners GmbH mit IMU- und BLE-Sensoren in jedem der drei Geräte



(d) Beacon Nr. 1 und Beacon Nr. 2 der MotionMiners GmbH

Abb. 5.5 Sensoren zur Erfassung der Bewegungen von Probanden und Kommissionierwagen

Probanden die Kamera während der Aufnahme neu justierten. Insbesondere Proband P01 korrigierte zu Beginn häufig die Kameraposition.

Die Aufnahme erfolgte mit 29.97 fps und wurde nur während eines Batteriewechsels unterbrochen.

Stationäre Kameras: Zusätzlich zu den mobilen Kameras wurden sechs stationäre Kameras (Mevo) von Logitech verwendet (siehe Abbildung 5.5 (b)), um das gesamte Testfeld zu erfassen. Diese Kameras ermöglichten eine Third-Person View (TPV) der Probanden (siehe Abbildung 5.6 (d)-(i)). Die TPV-Videos wurden als sekundäre Datenquelle für die Annotationen und Revisionen verwendet. Die Aufnahmen erfolgten ebenfalls mit 29,97 fps und liefen während der gesamten Session ohne Unterbrechung, wodurch eine lückenlose Dokumentation gewährleistet war.

Tragbare Geräte mit IMUs und BLE RSSI-Sensoren: Die Bewegungen der Probanden wurden mit tragbaren Sensoren aufgezeichnet, die aus drei Geräten der MotionMiners GmbH bestanden (siehe Abbildung 5.5 (c)). Jedes



(a) Proband P13: Position im *Verpackungs-/Sortierbereich*



(b) Proband P14: Position auf dem *Weg* vor dem *Kartonbereich*



(c) Proband P15: Position im vorderen Bereich des *Gassenwegs 4*



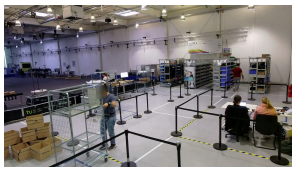
(d) Stationäre Kamera 1: Position im *Kartonbereich*, ausgerichtet auf die *Gassenwege* und die stationäre Kamera 2



(e) Stationäre Kamera 2: Position im *Gassenweg 3*, gegenüber der stationären Kamera 1



(f) Stationäre Kamera 3: Position im *Büro*



(g) Stationäre Kamera 4: Position im *Warenabgabe-/-annahmebereich*



(h) Stationäre Kamera 5: Position gegenüber dem *Warenabgabe-/-annahmebereich* und dem Hallentor



(i) Stationäre Kamera 6: Position ausgerichtet auf den *Verpackungs-/Sortierbereich* und den *Gassenweg 1*

Abb. 5.6 Synchronisierte Kameraperspektiven bei Frame 31.171 in Session 5. **(a)–(c)** zeigen die FPVs der drei Probanden, die von mobilen Kameras aufgenommen wurden. **(d)–(i)** zeigen die TPVs der sechs stationären Kameras, die entsprechend dem Datensatz nummeriert sind. Die Position der stationären Kameras ist in Abbildung 5.7 des Grundrisses dargestellt.

Gerät ist mit einem 3-achsigen IMU und einem BLE-RSSI-Sensor ausgestattet. Die drei Geräte wurden an beiden Handgelenken und mit einem Gurt im vorderen Bereich des Torso befestigt.

Jeder Proband trug zwei dieser Sets, um Sensorausfälle zu minimieren und eine Analyse der Datenqualität mittels Vergleichen zu ermöglichen. Während der gesamten Aufnahmesession blieben die tragbaren Geräte an den Probanden befestigt. Die IMUs umfassen lineare Beschleunigungs- und Drehimpulssensoren, die mit einer Abtastrate von 100 Hz arbeiten. Der Bluetooth-Sensor maß den RSSI für alle empfangenen Beacon-Emitter-Signale mit einer Abtastrate von 10 Hz.

Alle Sensordaten wurden während der Aufnahmen auf den Sensoren gespeichert und nach Abschluss der Aufnahme übertragen. Dieses Vorgehen schloss mögliche Störquellen – etwa durch drahtlose Datenübertragung – aus und stellte einen robusten, unterbrechungsfreien Datenerfassungsprozess

ohne Eingriffe sicher.

Beacon Emitter: Um die Positionen der Probanden zu erfassen, wurden 54 Bluetooth-Beacons (siehe Abbildung 5.5 (d)) gleichmäßig im Picking Lab verteilt (siehe Abbildung 5.7). Die Beacons wurden in einer Höhe von 0,7 bis 1,3 m an Regalen, Wänden, einem Tisch und Absperrständern befestigt. Zusätzlich wurde an jedem Kommissionierwagen in einer Höhe von 0,9 m ein Beacon angebracht, um dessen Position zu verfolgen, wenn ein Proband ihn benutzte.

Eine Herausforderung bei der Positionsverfolgung ergibt sich aus den unterschiedlichen Umgebungsbedingungen. In den *Gassen* zwischen den Regalen werden die Bluetooth-Signale physisch durch das Metall der Fachbodenregale und die eingelagerten Artikel abgeschirmt. Dies führt zu einer stärkeren Signaldämpfung, was die lokale Positionierung vereinfacht, da sich die Signale eindeutig bestimmten Bereichen zuordnen lassen. Im Gegensatz dazu breiten sich Bluetooth-Signale in offenen Bereichen wie dem *Büro*, der *Basis* und dem *Verpackungs-/Sortierbereich* gleichmäßiger aus. Diese Gleichverteilung der Signale erschwert die zonenbasierte Positionierung, da es schwieriger ist, zwischen den Bereichen zu unterscheiden, und die Wahrscheinlichkeit von Fehlzuordnungen steigt. Eine anfängliche Kalibrierung für jede Zone hilft, Unterschiede in den Signalausbreitungen zu berücksichtigen.

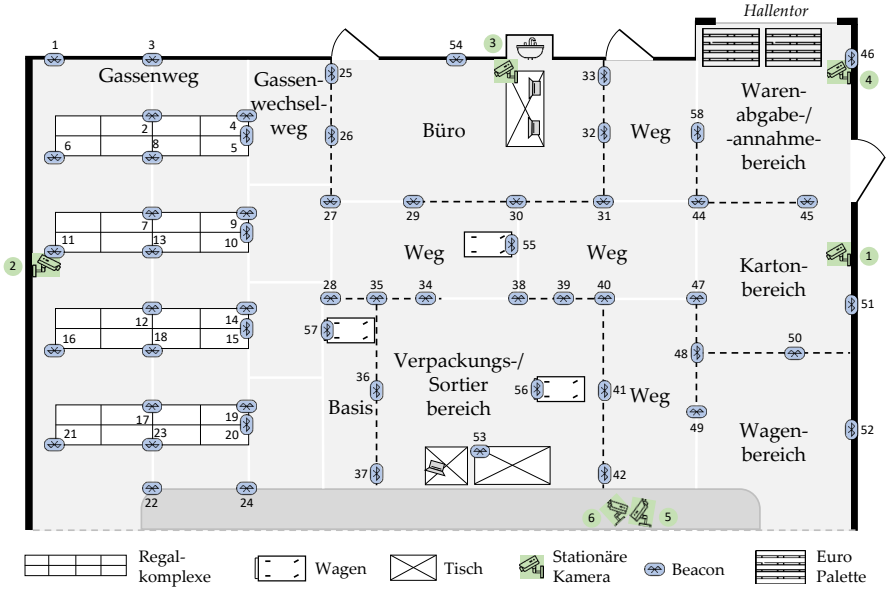


Abb. 5.7 Grundriss des Picking Labs: Positionen der sechs stationären Kameras (grün) und der 57 Beacons (blau). Die Beacons 1–42, 44–54 und 58 sind stationär, während die Beacons 55–57 dynamisch sind und an den Kommissionierwagen angebracht sind.

Schritt 6: Probandeninformation erstellen

Die Probandeninformation (siehe Tabelle A.12) adressiert die folgenden Fragen:

- Warum wird diese Studie durchgeführt?
- Wie läuft die Studie ab und was wird von mir als Proband erwartet?
- Welche Risiken oder Unannehmlichkeiten entstehen durch die Teilnahme an der Studie?
- Wer ist von der Teilnahme ausgeschlossen?
- Entstehen mir durch die Teilnahme an der Studie Kosten? Erhalte ich eine Aufwandsentschädigung?
- Bin ich während der Studie versichert?
- Kann meine Teilnahme vorzeitig beendet werden?
- Was geschieht mit meinen personenbezogenen Daten?
- Welche gesetzlichen Rechte habe ich in Bezug auf meine Daten?
- An wen kann ich mich für weitere Informationen wenden?

Schritt 7: Probandeneinwilligungserklärung erstellen

Die Probandeneinwilligungserklärung ist Bestandteil der Probandeninformation (siehe Tabelle A.12). Sie adressiert die folgenden Punkte:

- eine Datenschutzerklärung, die es den Probanden ermöglicht, frei, ausdrücklich und in voller Kenntnis der Sachlage der Erhebung, Verarbeitung und Veröffentlichung ihrer personenbezogenen Daten zuzustimmen oder diese abzulehnen,
- Optionen für die Probanden zur Angabe der personenbezogenen Daten (z. B. Fotos, Videos, IMU-Daten), deren Veröffentlichung zulässig ist,
- die Bestätigung der freiwilligen Teilnahme,
- die Bestätigung, dass eine informative Einweisung stattgefunden hat, und
- eine Erklärung, dass die Probanden keine Vorerkrankungen haben, die sie daran hindern, die Studienverfahren sicher zu absolvieren.

Schritt 8: Fragebogen für Probanden erstellen

Zur systematischen Erfassung von Probandencharakteristiken wurde eine Online-Umfrage erstellt, in der Angaben zu Alter, Geschlecht, Händigkeit, Körpergröße, Körpermasse, aktivitätsbezogener Erfahrung, beruflicher Qualifikation, körperlicher Beeinträchtigung sowie zum kulturellen Hintergrund und zur Sprache erhoben werden. Die Erfassung körperlicher Beeinträchtigungen dient dem Abgleich mit den Ausschlusskriterien und damit dem Schutz der Probanden.

Schritt 9: Ethikvotum einholen

Das Vorhaben der Datenaufnahme einschließlich der Dokumentvorlage der Probandeninformation und -einwilligungserklärung wurde von einer unabhängigen Ethikkommission genehmigt (siehe Abschnitt A.4).

5.1.2 Phase 2 | Vorbereitung der Datenaufnahme

Schritt 10 und 11: Probandenakquise und -charakteristiken

Insgesamt nahmen 18 Probanden an der Datenerhebung teil (siehe Abbildung 5.8). Das Auswahlverfahren hatte das Ziel, die arbeitende Bevölkerung im deutschen Lagerhaltungssektor realitätsnah abzubilden (siehe Datensatztaxonomie in Tabelle A.1). Entsprechend wurden ausschließlich Personen bis zu einem Alter von 67 Jahren einbezogen, da für nach 1964 Geborene in Deutschland ein gesetzliches Renteneintrittsalter von 67 Jahren gilt. Letztlich umfasste die Stichprobe Probanden im Alter von 21 bis 67 Jahren mit einer breiten Altersverteilung.

Laut einer Studie der Bundesvereinigung Logistik e. V. (BVL) aus dem Jahr 2019 beträgt der Frauenanteil im Logistik-, Transport- und Verkehrssektor etwa 23 % [BVL2019]. Den höchsten Frauenanteil weisen logistiknahe Dienstleister (23 %) und die Lagerei (30 %) auf. Bei Zugrundelegung dieses Prozentsatzes ergibt sich für eine Stichprobe von 18 Probanden ein Anteil von 4,14 bis 5,4 Frauen. Dementsprechend wurden fünf Frauen für die Studie akquiriert, von denen vier (22,22 %) teilnahmen.



Abb. 5.8 Übersicht der 18 Probanden des DaRA-Datensatzes

Um eine vielfältige Stichprobe hinsichtlich Bewegungsmustern, Verhaltensweisen und technologischer Kompetenz zu gewährleisten, wurden zu-

sätzliche demografische und physische Merkmale berücksichtigt. Die Körpergröße der Probanden reichte von 160 cm bis 187 cm, während ihre Masse zwischen 62 kg und 103 kg variierte (siehe Tabelle 5.2). Weiterhin waren mehrere Muttersprachen vertreten, darunter Bengali, Deutsch, Englisch, Griechisch und Türkisch. Die Einbeziehung der sprachlichen Vielfalt war beabsichtigt, da in Lagerumgebungen häufig Arbeitnehmer mit unterschiedlichem sprachlichem Hintergrund beschäftigt sind.

Tabelle 5.2 Probandencharakteristiken im Überblick. Alle Daten wurden mittels einer digitalen Umfrage (Probandenfragebogen) erhoben, die die Probanden selbstständig ausfüllten.

ID	Geschlecht	Alter	Masse	Größe	Händigkeit	Beschäftigung	Erfahrung		
	[W/M]	[Jahre]	[kg]	[cm]	[L/R]	Status	Komm.	Verp.	Vgl. Studie
P01	W	32	68	171	R	Student	2	3	6
P02	M	27	76	167	R	Student	3	6	6
P03	M	64	69	171	R	Arbeitnehmer	6	5	5
P04	M	31	85	183	L	Arbeitnehmer	5	4	6
P05	M	67	100	177	R	Rentner	6	3	6
P06	M	24	82	178	R	Student	4	6	6
P07	M	41	70	180	R	Arbeitnehmer	6	5	6
P08	W	29	62	163	R	Student	6	6	6
P09	M	21	85	180	R	Student	6	6	6
P10	M	28	85	160	R	Student	3	3	6
P11	M	59	85	178	R	Arbeitnehmer	3	2	6
P12	M	43	103	186	R	Arbeitssuchender	6	6	4
P13	W	52	66	175	R	Arbeitnehmer	5	4	6
P14	M	32	80	176	R	Arbeitnehmer	6	5	5
P15	M	43	88	177	R	Arbeitnehmer	6	5	6
P16	M	29	100	175	R	Student	6	3	6
P17	W	25	75	180	R	Arbeitnehmer	6	5	6
P18	M	26	80	187	R	Student	6	6	6
Min.		**21**	**62**	**160**					
$\bar{x}$		**37.4**	**81.1**	**175.8**					
Max.		**67**	**103**	**187**					

Anmerkung: W = weiblich, M = männlich. Die Erfahrung in der Kommissionierung, Verpackung und vergleichbaren Studien ist auf einer Skala von 1 (umfangreiche Erfahrung) bis 6 (keine Erfahrung) angegeben.

Die Stichprobe umfasste einen linkshändigen Probanden. Angesichts der Tatsache, dass der durchschnittliche Anteil linkshändiger Personen in der Gesamtbevölkerung bei 10,6 % liegt [Pap+20], wäre eine etwas höhere Vertretung wünschenswert gewesen, was auf eine geringfügige Verzerrung der Stichprobe hindeutet.

Die Probanden wurden nicht aufgrund ihrer vorherigen Lagererfahrung ausgewählt. Sieben Probanden hatten jedoch bereits Erfahrung in der Kommissionierung, während 12 Probanden Erfahrung im Verpackungsbereich hatten, die sie durch Ausbildungen, Praktika oder Teilzeitjobs erworben

hatten. Einer dieser Probanden (P01) hatte Vollzeit Berufserfahrung als Industriekauffrau. Drei Probanden hatten zuvor an einer ähnlichen Studie teilgenommen (LARa [Nie+20a]). Alle 18 Probanden verfügten über eine Hochschulzugangsberechtigung und hatten entweder einen Hochschulabschluss oder befanden sich zum Zeitpunkt der Studie in einem Studium. Der potenzielle Einfluss des Bildungshintergrunds auf Bewegungsmuster und Verhaltensweisen wurde in der Datenaufnahme nicht explizit analysiert, da dessen Auswirkungen als vernachlässigbar angesehen wurden.

An jeder Aufnahmesession nahmen drei Probanden gleichzeitig teil. Zur leichten Unterscheidung der Probanden innerhalb einer Session trugen sie Oberteile in verschiedenen Farben (siehe Abbildung 5.8). Beispielsweise trugen die Probanden P13, P14 und P15 in Session 5 ein rosa, ein blaues und ein rotes Oberteil (Videomaterial aus Session 5, siehe Abbildung 5.6).

Schritt 12: Aufnahmeprotokoll

Speziell für die Datensatzerstellung im Picking Lab wurde ein Protokoll erstellt, welches unter anderem die folgenden Punkte enthält:

vor der Datenaufnahme:

- Sensorspezifikationen: Sensortyp, Hersteller, Abtastrate, Anzahl, Platzierung
- Umgebungsbedingungen: Farbe der Oberteile der Probanden
- Labor: Dokumentation des Versuchsaufbaus anhand von Fotos, Grundrissmaßen sowie Informationen zu den verwendeten Objekten (Typ, Gewicht und Abmessungen)
- Zuständigkeiten: Zuweisung der Rollen unter den Studienleitern
- Zuweisung der Probanden zu den Sessions und den Sensor-IDs

während der Datenaufnahme:

- Aktivitätsplan: Struktur einer Session, Auftragsreihenfolge je Proband, Kalibrierungsroutinen, Pausen und Wiederholungen
- Sensorüberwachung: Batteriestände und aktiver Aufnahmestatus
- Unerwartete Ereignisse: Sensorausfälle, abweichendes Verhalten der Probanden

unmittelbar nach der Datenaufnahme:

- Dokumentation der Sensorplatzierung
- Dokumentation der Artikel durch Fotos

Schritt 13: Sensorsysteme

Nach der Beschaffung der mobilen und stationären Kameras erfolgte eine Überprüfung von Zuverlässigkeit, Synchronisation und Datenqualität als

Vorbereitung auf die Testaufnahme. Die tragbaren Sets und Beacons von MotionMiners GmbH wurden vom Fraunhofer-IML bereitgestellt. Aufgrund eines, während der Sensorüberprüfung festgestellten Defekts wurde der Beacon 43 von den Datenaufnahmen ausgeschlossen.

Schritt 14: Aufnahmeumgebung einrichten

Layout des Versuchsaufbaus: Der freie Bereich des Picking Labs wurde in verschiedene Arbeitsbereiche unterteilt. Einschließlich des einzonigen *Gassenwegs* innerhalb der Fachbodenregalanlage umfasst der Versuchsaufbau neun Hauptbereiche (siehe farbliche Unterteilung in Abbildung 5.9). Weiterhin wurden der *Gassenweg*, der *Gassenwechselweg* und der *Weg* in weitere Zonen unterteilt, um detaillierte Prozessschritte abzudecken.

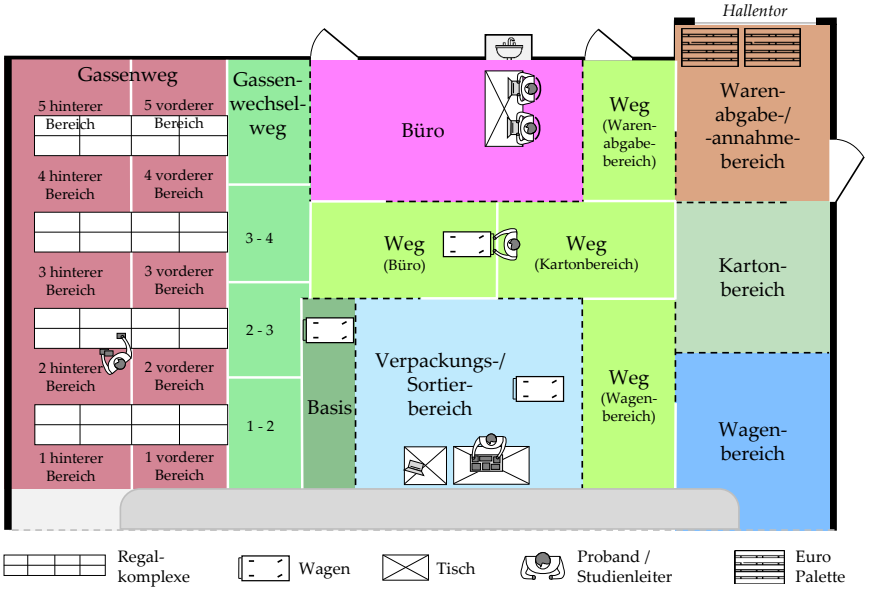


Abb. 5.9 Zonierter Grundriss des Picking Labs in neun farblich gekennzeichneten Hauptbereichen des Versuchsaufbaus. Die Farben entsprechen dem Kodierungsschema des Annotationstools Sequence Attribute Retrieval Annotator (SARA) [Moy+26; Nie+23]. Die gestrichelten schwarzen Linien stellen physische Grenzen dar, die durch Absperrständer mit Gurtbändern gebildet wurden, während die durchgezogenen weißen Linien konzeptionelle Grenzen anzeigen, die durch Klebeband auf dem Boden markiert waren.

Realistische Materialflussimplementierung: Im Gegensatz zu den isolierten Prozessen, die typischerweise in HAR-Datensätzen dargestellt werden, wurde ein ganzheitlicher, realistischer, lagerplatzspezifischer Materialfluss implementiert. Während jeder Aufnahmesession durchliefen drei Probanden gleichzeitig den gesamten Materialfluss, wie in Abbildung 5.9 dargestellt. Die Studienleiter fungierten als Lagerleiter, die sich hauptsächlich im *Büro* auf-

hielten, wo sie Aufträge zuwiesen und die informationstechnische Führung verwalteten, Hardware nach Abschluss der Aufträge entgegennahmen und den Probanden bei Bedarf halfen. Der Versuchsaufbau ist in Abbildung 5.10 dargestellt. Das Foto wurde im *Verpackungs-/Sortierbereich* (siehe hellblauer Bereich in Abbildung 5.9) mit Blick auf das *Büro* aufgenommen. Im Büro sitzt eine Studienleiterin an einem Schreibtisch, an dem die Probanden ihre Aufträge erhielten. Hinter der Studienleiterin, aus Sicht des Fotos rechts, befindet sich der *Warenabgabe-/-annahmebereich* neben dem schwarzen Hallentor. Die Kisten davor kennzeichnen den *Kartonbereich*. Der *Wagenbereich* befindet sich weiter vorn, in dem drei Kommissionierwagen stehen. Diese Bereiche sind durch einen T-förmigen Weg miteinander verbunden. Auf der linken Seite des Fotos sind die *Basis*, die *Gassenwechselwege* und die Fachbodenregalanlage mit ihren acht nummerierten Regalkomplexen und fünf *Gassenwegen* zu erkennen.



Abb. 5.10 Panoramablick auf den Versuchsaufbau und die funktionalen Bereiche des Picking Labs

Schritt 15: Testaufnahme

Die technischen Systeme (darunter die Sensoren zur Bewegungserfassung, das WMS, der Handschuhscanner sowie das MDE-Gerät), ebenso wie der Versuchsaufbau und der Aufnahmeablauf, wurden zwei Monate vor der Hauptdatenaufnahme getestet. Die resultierenden Daten wurden erfolgreich exportiert und in das Annotationstool integriert, sodass die gesamte Pipeline von der Datenerfassung bis zur Vorverarbeitung evaluiert werden konnte. Während der Testaufnahme wurde eine Fehlfunktion im WMS festgestellt und nach einigen Tagen behoben. Ebenso zeigten andere Komponenten Verbesserungspotenzial. Beispielsweise konnten die am Brustkorb befestigten mobilen Kameras das Sichtfeld und den Bewegungsbereich der Probanden nicht ausreichend erfassen. Als Korrekturmaßnahme wurden Kopfhalterungen und Weitwinkelobjektive angeschafft. An der Versuchsanordnung wurden nur geringfügige räumliche Anpassungen vorgenommen. Zu den verfahrenstechnischen Verbesserungen gehörten überarbeitete Kommissionieraufträge und standardisierte Anweisungen für die Probanden.

5.1.3 Phase 3 | Durchführung der Datenaufnahme

Schritt 16: Einwilligungserklärung einholen

Alle am Datensatz beteiligten Probanden wurden Wochen vor der Datenaufnahme durch die Probandeninformation schriftlich und in einem persönlichen Gespräch mit dem Studienleiter mündlich aufgeklärt. Am Tag der Datenaufnahme wurden vor der Aufnahme offene Fragen besprochen und die Probandeneinwilligungserklärung zur Teilnahme an der Datenaufnahme sowie zur Veröffentlichung der Daten wurde unterschrieben.

Schritt 17: Dokumentation

Während des Dokumentationsschrittes wurde sichergestellt, dass alle Probanden den Fragebogen und die Probandeneinwilligungserklärung unterschrieben haben. Die Studienleiter führten das Protokoll (siehe Schritt 12 von DaRA) vor, während und nach den Aufnahmen.

Schritt 18 und 19: Sensorkalibrierung und Sensorsynchronisation

Vor dem Probelauf wurden die Sensoren kalibriert. Die Sensorsynchronisation der stationären Kameras erfolgte appbasiert über eine Kombination aus Bluetooth (zur Geräteerkennung) und WLAN (für die Signalübertragung). Die Metadaten der mobilen Kameras wurden ebenfalls appbasiert mithilfe von QR-Codes synchronisiert. Um die Datenströme von Kameras und den tragbaren Geräten zu synchronisieren, wurden Synchronisationsbewegungen definiert und als Label in die Klassenskategorie *Hauptaktivität* aufgenommen. Zu den Synchronisationsbewegungen gehören das Zusammenführen der ausgestreckten Arme über dem Kopf, das Zusammenführen der ausgestreckten Arme vor der Brust und Sprünge.

Schritt 20: Probelauf

Vor der Hauptaufnahme absolvierten alle drei Probanden einer Session zusammen Probeläufe. In dieser Phase wurden sie mit der Hardware zur informationstechnischen Führung (Pickliste mit Stift, Pickliste mit Handschuhscanner sowie MDE-Gerät) und dem gesamten Kommissionierprozess vertraut gemacht. Zu Schulungszwecken bearbeiteten sie drei Aufträge mit jeweils drei Positionen. Dieser Probelauf diente ausschließlich der Einarbeitung in die Prozesse und Geräte und wurde nicht aufgezeichnet. Anschließend wurden die Probanden mit zwei Sets der tragbaren Geräte und einer mobilen Kamera ausgestattet, womit die Datenerfassung begann.

Schritt 21: Hauptaufnahme

Um einen natürlichen Bewegungsablauf und authentisches Verhalten der Probanden zu gewährleisten, nahmen die Studienleiter nach dem Probelauf

die Rolle der Lagerleiter ein, gaben jedoch nur minimale Anweisungen. Zu Beginn jeder Session führten die Probanden bis zu drei Synchronisationsbewegungen im *Büro* durch.

Nach der Synchronisation startete die **Auslagerung**. Jeder Proband hatte die Aufgabe, die Szenarien 1–3 abzuarbeiten (siehe oberer Pfad in Abbildung 5.11 und Schritt 4). Die papierbasierten Picklisten waren in ausreichender Menge verfügbar. Umgekehrt standen nur ein MDE-Gerät und ein Handschuhscanner zur Verfügung, was im Büro teils zu Wartezeiten führte, da Probanden auf die Rückgabe der Hardware warteten. Die Hardware für die informationstechnische Führung stellte damit einen kritischen Engpass dar. Deswegen wurden die Szenarien 2 und 3 nicht parallel durchgeführt, was zu einer unterschiedlichen Reihenfolge der ersten drei Szenarien zwischen den Probanden führte (siehe Abschnitt A.1.6). Neben Hardware für die informationstechnische Führung war der Verpackungsbereich ein Engpass. An einem Verpackungsplatz war nur Raum für einen Probanden.

Nach Abschluss der ersten drei Auslagerungszenarien startete die **Einlagerung** (siehe unterer Pfad in Abbildung 5.11). Die drei Kundenaufträge (ID 2904, 2905, 2906, siehe Tabellen A.6 bis A.8) standen jeweils dreimal im *Warenabgabe-/-annahmebereich* zur Verfügung. Jeder Proband erhielt einen dieser Kundenaufträge, den er komplett, also dreimal, auspackte und einlagerte.

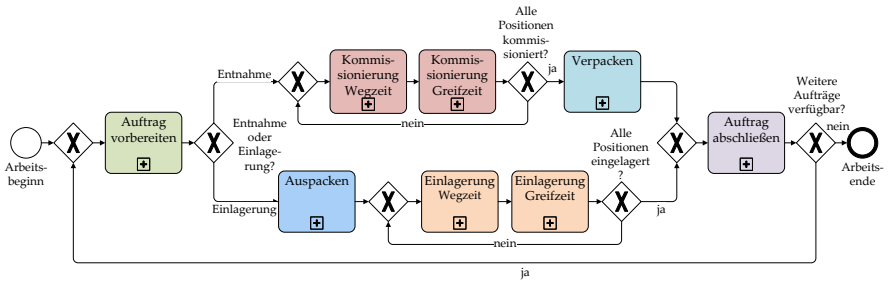


Abb. 5.11 Idealisiertes BPMN der Grobprozesse *Auslagerung* (oberer Pfad) und *Einlagerung* (unterer Pfad) mit ihren Teilprozessen.

Nach Abschluss der Aus- und Einlagerungen einzelner Aufträge gemäß dem Single Order Picking Prinzip führten die Probanden P01, P04, P09 und P14 ein Multi Order Picking durch. Dabei entnahmen sie (Szenario 7) zwei Kundenaufträge gleichzeitig (2904+2905, siehe Tabelle A.9) und lagerten diese anschließend wieder ein (Szenario 8).

Am Ende jeder Session führten die Probanden erneut bis zu drei Synchronisationsbewegungen durch.

Die Arbeitsabläufe der Grobprozesse *Auslagerung* und *Einlagerung*, wie in Abbildung 5.11 dargestellt, stellen ein idealisiertes Modell dar. Während der Datenerfassung kam es gelegentlich zu Abweichungen. Eine detailliertere

Visualisierung der idealisierten Teilprozesse aus Abbildung 5.11 findet sich in Abschnitt A.1.1.

5.1.4 Phase 4 | Vorbereitung der Datenverarbeitung

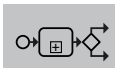
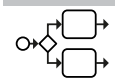
Schritt 22: Klassenlabels

Um die Ausführung der Szenarien zu beschreiben, wurden vor der Annotation 12 Klassenkategorie (KK) (KK01–KK12) definiert. Eine Übersicht der Klassenkategorien und dazugehörigen Klassenlabel (KL) sind in Tabelle 5.3 aufgeführt. Detaillierte Beschreibungen der Labels sind der veröffentlichten Dokumentation zu entnehmen [Nie+26b].

Tabelle 5.3 Klassenkategorien und Klassenlabels

Klassenkategorien [KK]				Klassenlabels [KL]
Symbol	ID	Name	M/K	Nr.
	KK01	Hauptaktivität	M	15: KL001 bis KL015
	KL001 | Synchronisation; KL002 | Quittierung per Stift; KL003 | Quittierung per Touchscreen; KL004 | Quittierung per Taste; KL005 | Scannen; KL006 | Kommissionierwagen ziehen; KL007 | Kommissionierwagen schieben; KL008 | Handhabung überkopf; KL009 | Handhabung neutral; KL010 | Handhabung gebeugt; KL011 | Gehen; KL012 | Stehen; KL013 | Sitzen; KL014 | Andere Hauptaktivität; KL015 | Hauptaktivität unbekannt			
	KK02	Teilaktivität - Beine	M	8: KL016 bis KL023
	KL016 | Gangzyklus; KL017 | Schritt; KL018 | Stillstehen; KL019 | Sitzen; KL020 | Kniebeuge; KL021 | Ausfallschritt; KL022 | Andere Beinaktivität; KL023 | Beinaktivität unbekannt			
	KK03	Teilaktivität - Torso	M	6: KL024 bis KL029
	KL024 | Keine Beugung; KL025 | Leichte Beugung; KL026 | Starke Beugung; KL027 | Torsorotation; KL028 | Weitere Torsoaktivität; KL029 | Torsoaktivität unbekannt			
	KK04	Teilaktivität - Linke Hand	M	35: KL030 bis KL064
	Primäre Position: KL030 | Überkopf; KL031 | Neutral; KL032 | Gebeugt; KL033 | Position unbekannt **Art der Bewegung:** KL034 | Hinlangen, Greifen, Bewegen, Positionieren und Loslassen; KL035 | Manipulieren; KL036 | Halten; KL037 | Keine Bewegung; KL038 | Andere Bewegung; KL039 | Bewegung unbekannt **Objekt:** KL040 | Kein Objekt; KL041 | Großer Artikel; KL042 | Mittlerer Artikel; KL043 | Kleiner Artikel; KL044 | Werkzeug; KL045 | Kommissionierwagen; KL046 | Ladehilfsmittel; KL047 | Karton; KL048 | Sensoren am Körper; KL049 | Anderes Logistikobjekt; KL050 | Kein Logistikobjekt; KL051 | Objekt unbekannt **Werkzeug:** KL052 | Mobiles Datenerfassungsgerät; KL053 | Handschuhscanner; KL054 | Plastiktüte; KL055 | Pickliste; KL056 | Stift; KL057 | Taste; KL058 | Computer; KL059 | Luftpolsterfolie; KL060 | Packbandabroller; KL061 | Messer; KL062 | Versand-/Rücksendelabel; KL063 | Gummiband; KL064 | Anderes Werkzeug			
	KK05	Teilaktivität - Rechte Hand	M	35: KL065 bis KL099
	Primäre Position: KL065 | Überkopf; KL066 | Neutral; KL067 | Gebeugt; KL068 | Position unbekannt **Art der Bewegung:** KL069 | Hinlangen, Greifen, Bewegen, Positionieren und Loslassen; KL070 | Manipulieren; KL071 | Halten; KL072 | Keine Bewegung; KL073 | Andere Bewegung; KL074 | Bewegung unbekannt **Objekt:** KL075 | Kein Objekt; KL076 | Großer Artikel; KL077 | Mittlerer Artikel; KL078 | Kleiner Artikel; KL079 | Werkzeug; KL080 | Kommissionierwagen; KL081 | Ladehilfsmittel; KL082 | Karton; KL083 | Sensoren am Körper; KL084 | Anderes Logistikobjekt; KL085 | Kein Logistikobjekt; KL086 | Logistikobjekt unbekannt **Werkzeug:** KL087 | Mobiles Datenerfassungsgerät; KL088 | Handschuhscanner; KL089 | Plastiktüte; KL090 | Pickliste; KL091 | Stift; KL092 | Taste; KL093 | Computer; KL094 | Luftpolsterfolie; KL095 | Packbandabroller; KL096 | Messer; KL097 | Versand-/Rücksendeetikett; KL098 | Gummiband; KL099 | Anderes Werkzeug			

Tabellenfortsetzung

Klassenkategorien [KK]				Klassenlabels [KL]
Symbol	ID	Name	M/K	Nr.
	KK06	Auftrag	K	5: KL100 bis KL104
	KL100 | 2904; KL101 | 2905; KL102 | 2906; KL103 | Kein Auftrag; KL104 | Auftrag unbekannt			
	KK07	Hardware für die informationstechnische Führung	K	5: KL105 bis KL109
	KL105 | Liste und Stift; KL106 | Liste und Handschuhscanner; KL107 | Mobiles Datenerfassungsgerät; KL108 | Keine informationstechnische Führung; KL109 | Informationstechnische Führung unbekannt			
	KK08	Grobprozess	K	4: KL110 bis KL113
	KL110 | Auslagerung; KL111 | Einlagerung; KL112 | Anderer Grobprozess; KL113 | Grobprozess unbekannt			
	KK09	Teilprozess	K	10: KL114 bis KL123
	KL114 | Auftrag vorbereiten; KL115 | Kommissionierung - Wegzeit; KL116 | Kommissionierung - Greifzeit; KL117 | Auspacken; KL118 | Verpacken; KL119 | Einlagerung - Wegzeit; KL120 | Einlagerung - Greifzeit; KL121 | Auftrag abschließen; KL122 | Anderer Teilprozess; KL123 | Teilprozess unbekannt			
	KK10	Feinprozess	K	31: KL124 bis KL154
	KL124 | Auftrag und Hardware abholen; KL125 | Kommissionierwagen abholen; KL126 | Leere Kartons abholen; KL127 | Verpackte Kartons abholen; KL128 | Kommissionierwagen zur Basis transportieren; KL129 | Zum Verpackungs-/Sortierbereich transportieren; KL130 | Übergabe von verpackten Kartons; KL131 | Rückgabe von leeren Kartons; KL132 | Rückgabe des Kommissionierwagens; KL133 | Rückgabe der Hardware; KL134 | Warten; KL135 | Vorfall melden und klären; KL136 | Entfernen eines Kartons/Artikels vom Kommissionierwagen; KL137 | Bewegung zur nächsten Position; KL138 | Artikel in einem Regal platzieren; KL139 | Entnahme von Artikeln; KL140 | Bewegung zu einem Kommissionierwagen; KL141 | Karton/Artikel auf einen Tisch stellen; KL142 | Karton öffnen; KL143 | Füllmaterial oder Versandetikett entsorgen; KL144 | Sortieren; KL145 | Karton mit Füllmaterial füllen; KL146 | Versand-/Rücksendeetikett ausdrucken; KL147 | Rücksendeetikett vorbereiten oder hinzufügen; KL148 | Versandetikett anbringen; KL149 | Gummiband entfernen; KL150 | Karton verschließen; KL151 | Karton/Artikel in einen Kommissionierwagen legen; KL152 | Gummiband um den Karton binden; KL153 | Anderer Feinprozess; KL154 | Feinprozess unbekannt			
	KK11	Lokalisierung - Mensch	K	26: KL155 bis KL180
	Hauptbereich: KL155 | Büro; KL156 | Wagenbereich; KL157 | Kartonbereich; KL158 | Basis; KL159 | Verpackungs-/Sortierbereich; KL160 | Warenabgabe-/-annahmebereich; KL161 | Weg; KL162 | Gassenwechselweg; KL163 | Gassenweg **Weg:** KL164 | Weg (Büro); KL165 | Weg (Kartonbereich); KL166 | Weg (Wagenbereich); KL167 | Weg (Warenabgabebereich) **Gassenwechselweg:** KL168 | 1-2; KL169 | 2-3; KL170 | 3-4; KL171 | 4-5 **Gassenweg:** KL172 | 1; KL173 | 2; KL174 | 3; KL175 | 4; KL176 | 5; KL177 | Vorderer Bereich; KL178 | Hinterer Bereich **Sonstiges:** KL179 | Andere Lokalisierung; KL180 | Lokalisierung unbekannt			
	KK12	Lokalisierung - Kommissionierwagen	K	27: KL181 bis KL207
	Hauptbereich: KL181 | Übergang zwischen Bereichen; KL182 | Büro; KL183 | Wagenbereich; KL184 | Kartonbereich; KL185 | Basis; KL186 | Verpackungs-/Sortierbereich; KL187 | Warenabgabe-/-annahmebereich; KL188 | Weg; KL189 | Gassenwechselweg; KL190 | Gassenweg **Weg:** KL191 | Weg (Büro); KL192 | Weg (Kartonbereich); KL193 | Weg (Wagenbereich); KL194 | Weg (Warenabgabebereich) **Gassenwechselweg:** KL195 | 1-2; KL196 | 2-3; KL197 | 3-4; KL198 | 4-5 **Gassenweg:** KL199 | 1; KL200 | 2; KL201 | 3; KL202 | 4; KL203 | 5; KL204 | Vorderer Bereich; KL205 | Hinterer Bereich **Sonstiges:** KL206 | Andere Lokalisierung; KL207 | Lokalisierung unbekannt			

Anmerkung: M = menschliche Bewegung, K = Kontext, KK = Klassenkategorien, KL = Klassenlabels

Die ersten fünf Kategorien erfassen menschliche Bewegungen, angefangen von der *Hauptaktivität* (KK01) hin zu vier *Teilaktivitäten* (*Beine*, *Torso*, *Linke Hand*, *Rechte Hand* (KK02–KK05)). Teilaktivitäten werden als semantische Beschreibungen einer *Hauptaktivität* betrachtet, existieren aber auch unabhängig davon. In der Literatur werden solche semantischen Beschreibungen auch als Attribute, detaillierte Körperhaltungen oder atomare Aktionen bezeichnet [AR11].

Die Kategorien KK06–KK12 erfassen Kontextinformationen. Dazu gehören der *Auftrag* des Kunden (KK06), *Hardware für die informationstechnische Führung* (KK07), die Einbettung der Aktivität in *Prozesse* (KK08–KK10) und die *Lokalisierung* des Probanden (KK11) oder des Kommissionierwagens (KK12).

Bestimmte Kategorien sind hierarchisch organisiert. *Teilaktivität – Linke Hand* (KK04) und *Teilaktivität – Rechte Hand* (KK05) sind unterteilt in *Primäre Position*, *Art der Bewegung*, *Objekt* und *Werkzeug*, während die Klassen der *Lokalisierung* in *Hauptbereich*, *Weg*, *Gassenwechselweg*, *Gassenweg* und *Sonstiges* unterteilt ist.

Je nach Kategorie wurden zwischen vier und 35 Klassenlabels festgelegt; insgesamt existieren 207 unterschiedliche Labels. Entsprechend der Datensatztaxonomie decken die Labels die Labelkategorien *Körperhaltungen / statische Aktivitäten*, *Fortbewegung*, *Mensch-Objekt-Interaktion*, *zusammengesetzte Aktivitäten* und *Umwelt-/Verfahrenskontext* ab (siehe Tabelle A.1).

Schritt 23: Labelabhängigkeiten

Zur Steigerung der Annotationsqualität und der Annotationsgeschwindigkeit wurden intra- und interklassenkategorieabhängige Regeln definiert und für das Annotationstool in Form von CSV-Dateien implementiert. Insgesamt wurden 104.739 solcher Abhängigkeiten spezifiziert; im Folgenden werden exemplarische Regeln erläutert.

Für die Klassenkategorien *Hauptaktivität* (KK01), *Teilaktivität - Beine* (KK02), *Hardware für die informationstechnische Führung* (KK07), *Grobprozess* (KK08), *Teilprozess* (KK09) und *Feinprozess* (KK10) war pro Segment jeweils genau ein Label zulässig. Diese Intraklassenkategorieabhängigkeit reduzierte die Auswahl im Annotationstool auf ein einzelnes Label und verhinderte Mehrfachzuweisungen.

Für die Klassenkategorien *Teilaktivität - Torso* (KK03) und *Auftrag* (KK06) erlaubten die definierten Abhängigkeiten hingegen die Auswahl von ein bis zwei Labels. Die Lokalisierungsklassen (KK11 und KK12) waren so strukturiert, dass pro Hauptbereich genau ein Label auszuwählen war, während für die zugehörigen Teilbereiche Weg, Gassenwechselweg und Gassenweg weitere Labels zulässig waren. Abhängigkeiten zwischen Haupt- und Teilbereichen schränkten die Auswahl dabei stark ein, wodurch falsche Labelkombinationen innerhalb dieser Klasse vermieden wurden: So erforderte die

Auswahl des Labels *Weg* (KL161) zwingend die Auswahl exakt eines von vier möglichen Teilbereichslabels (KL164–KL167).

Interklassenkategorieabhängigkeiten verknüpften mehrere Klassenkategorien miteinander. Beispielsweise erforderte die Auswahl des Labels *Handhabung neutral* (KL009) in der Hauptaktivität (KK01) zwingend die Zuordnung eines korrespondierenden Manipulations- (KL035 bzw. KL070) oder Greiflabels (KL034 bzw. KL069) für entweder die rechte oder die linke Hand.

Weiterhin waren Prozesslabels an zulässige Lokalisierung des Menschen (KK11) gekoppelt. Die Prozesse der *Greifzeit* (KL116 und KL120) – definiert als die Zeit zur Entnahme bzw. Abgabe eines Artikels aus dem bzw. in das Regal, zur Quittierung der Entnahme sowie zur Ablage bzw. Entnahme im oder aus dem Kommissionierwagen – konnten ausschließlich ausgewählt werden, wenn sich der Proband in den Lokalisierungen *Basis* (KL158), *Gassenwechselweg* (KL162) oder *Gasse* (KL163) befand.

Schritt 24: Annotationsmethode

Parallel zur Vorbereitung und Durchführung der Datenaufnahme wurden die Annotationsmethoden im Einklang mit den definierten Klassenlabels und verfügbaren Sensordaten entwickelt und auf ihre Tauglichkeit überprüft.

Methodenentwicklung: Ausgangspunkt für die Methodenentwicklung waren Erfahrungswerte durch die Annotation der Datensätze LARa und CAARL sowie der in [Tra+26] beschriebene *Silberstandard*. Bei dem Silberstandard werden Aufnahmen von genau einer geschulten Hilfskraft annotiert und anschließend von genau einer geschulten Hilfskraft revidiert. Durch diesen Standard wurden eine relativ hohe Annotationsqualität bei zugleich relativ geringen Annotations- und Revisionszeiten und damit einhergehend auch geringe Kosten erreicht [Tra+26].

Annotatorenerfahrung: Für die Annotation und Revision von DaRA wurde der Silberstandard angepasst. Statt ausschließlich *geschulte Hilfskräfte* wurden zusätzlich auch *geschulte Experten* aus dem Anwendungsbereich Logistik als Annotatoren und Revisoren herangezogen. Insgesamt wurden 15 Experten und geschulte interne Hilfskräfte akquiriert.

Annotationsanzahl je Aufnahme: Dem Silberstandard entsprechend wurde jede Aufnahme nach dem Single-Annotator-Prinzip von einer geschulten Hilfskraft exakt einmal manuell annotiert (*Einzelannotation*) und anschließend von einem Experten einmal manuell revidiert. Einzige Abweichung vom Silberstandard stellt die Klassenkategorie *Hauptaktivität* dar, welche viermal von geschulten Hilfskräften revidiert wurde (siehe Schritt 30).

Kategorieweise, sequenzielle Annotation: Für die Annotation wurde eine *kategorieweise, sequenzielle Annotationsmethode* eingesetzt. Anstatt alle Klassenkategorien parallel zu annotieren, erfolgte die Annotation schrittweise, entweder einzelkategorisch oder in kleinen Gruppen von zwei bis drei Kategorien. Die Kategorien *Hauptaktivität* (KK01), *Teilaktivitäten* (KK02–KK05)

sowie *Lokalisierungen* (KK11–KK12) wurden jeweils einzeln annotiert, während die Kategorien KK06–KK08 und KK09–KK10 gruppenweise annotiert wurden. Ziel dieses Vorgehens ist die Reduktion der annotativen Komplexität, um sowohl die Annotationszeit zu verkürzen als auch die Konsistenz der gesetzten Labels zu erhöhen.

Labelzeitstruktur: Die Zeitstruktur der Labels wurde als segmentweise festgelegt, d. h. die Labelsegmente weisen flexible Dauern, basierend auf den natürlichen Beginn- und Endpunkten der Bewegungen, auf. Der Beginn und das Ende dieser Segmente sowie die Auswahl der Labels werden durch den Annotator bestimmt.

Exklusivität von Labels: Je nach Klassenkategorie wurde entweder ein Einzel-Label oder Mehrfach-Labels angewendet. Bei Einzel-Labels wird jedem Segment genau ein Label zugewiesen (KK01, KK02, KK07, KK08, KK09 und KK10). Im Gegensatz dazu waren Mehrfach-Labels entweder zulässig (KK03, KK06, KK11, KK12) oder erforderlich (KK04, KK05).

Labelsicherheit: Alle Labels wurden als harte Labels, also mit eindeutiger Zuordnung und ohne Angaben zu Sicherheit oder Wahrscheinlichkeiten, annotiert. Eingeschränkt wurde die Auswahl durch die definierten Labelabhängigkeiten (siehe Schritt 23).

Die Taxonomie der Annotationsmethoden und der Labelstruktur sind Tabelle A.1 zu entnehmen.

Schritt 25: Annotationstool

Für die Annotation und Revision wurde das Annotationstool SARA [Moy+26; Nie+23] eingesetzt. Ausschlaggebend für diese Wahl war die Möglichkeit, mehrere Videostreams während der Annotation parallel abzuspielen. Dadurch konnten unterschiedliche Kameraperspektiven berücksichtigt und bei Bedarf während des Annotationsprozesses gewechselt werden. Die Integrierungsmöglichkeit von definierten Labelabhängigkeiten war ein weiterer Grund für die Wahl des Tools. Wie die exemplarische Darstellung einer Revision im Annotationstool SARA zeigt, wurden die Videos der mobilen Kameras (siehe Abbildung 5.12 links) als primäre Quelle verwendet, wohingegen die Videos der sechs stationären Kameras (siehe zwei Videostreams in Abbildung 5.12 rechts) bei Bedarf als sekundäre Quelle dienten.

Die kontinuierliche Weiterentwicklung des SARA-Annotationstools ist hervorzuheben. Diese erfolgte maßgeblich im Zuge der fortlaufenden Annotation des LARa-Datensatzes. Aktuell wird das Tool von der MotionMiners GmbH zur Annotation von Aktivitäten auf Basis von Videodaten aus Lager- und Produktionsumgebungen eingesetzt.

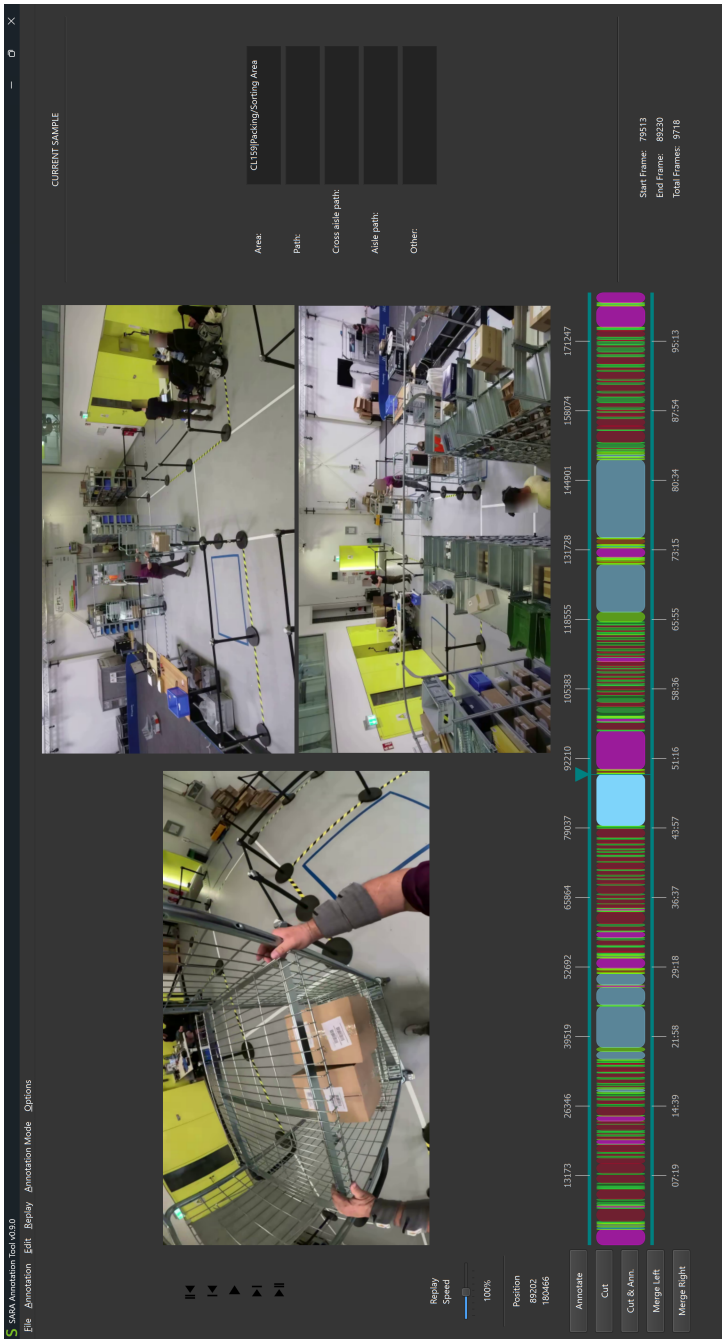


Abb. 5.12 Exemplarische Darstellung einer Revision einer vollständig annotierten Aufnahme der Klassenkategorie *Lokalisierung - Mensch* (KK11) von Proband P05 im Annotationstool SARA [Moy+26; Nie+23]

Schritt 26: Annotationsrichtlinien und Schulung

Jeder Annotator und Revisor erhielt vor Beginn der Annotation eine Schulung, in der das Annotationstool, der Annotationsablauf sowie die zu verwendenden Labels erläutert wurden. Die Labelerklärungen erfolgten kategoriespezifisch entsprechend den Klassenkategorien, die zur Annotation oder Revision vorgesehen waren, um für den Annotator redundante Informationen zu vermeiden. Zur Unterstützung und als Referenz wurden den Teilnehmenden Annotationsrichtlinien zur Verfügung gestellt, welche die Inhalte der Schulung zusammenfassten.

Zur Sicherstellung eines einheitlichen semantischen Verständnisses der Labels und des Annotationsablaufs sowie zur Gewährleistung einer hohen Annotationsqualität führten alle Annotatoren und Revisoren nach der Schulung Testannotationen durch. Für die Klassenkategorien KK06–KK08 wurde die gesamte Aufnahme von Proband P09 testannotiert. Für die anderen Kategorien wurden Auszüge von mehr als fünf Minuten von den Aufnahmen der Probanden P04, P05 und P06 testannotiert. Die Annotatoren hatten einen ausreichend hohen Cohen's-κ-Wert zu erreichen, um mit der Annotation der Hauptaufnahmen fortzufahren. Zu Trainingszwecken kontrollierten die Revisoren die Testannotationen ebenso für ihre jeweiligen Klassenkategorien.

Die Testannotationen, -revisionen und -videos wurden als eigenständiger Datensatz veröffentlicht [Nie+26c].

5.1.5 Phase 5 | Durchführung der Datenverarbeitung

Schritt 27: Datenexport und -kontrolle

Die Datenaufnahme erstreckte sich über drei Tage und umfasste insgesamt sechs Sessions. Pro Session nahmen jeweils drei Probanden parallel im Picking Lab teil (siehe Tabelle 5.4). Nach Abschluss der Aufnahmen wurden die Sensordaten exportiert und gemeinsam mit dem Protokoll auf Vollständigkeit überprüft.

Insgesamt wurden von 18 Probanden über einer Gesamtdauer von 31:55:26 Stunden (hh:mm:ss) Daten mithilfe von mobilen Kameras aufgezeichnet. Überdies wurden weitere 77 Stunden Videomaterial durch die sechs stationären Kameras erfasst. Die Datenkontrolle und -auswertung zeigen deutliche Variationen in den individuellen Aufnahmedauern der Probanden, die zwischen 01:20:41 und 02:35:11 Stunden liegen. Diese Unterschiede lassen sich auf Faktoren wie individuelle Arbeitsgeschwindigkeit, technologische Kompetenz, absolvierte Szenarien, ungeplante Fehler, Wartezeiten, Gewöhnungseffekte sowie Ermüdung zurückführen.

Arbeitsgeschwindigkeit: Die Dauer zeigt einen moderaten altersbedingten Anstieg der benötigten Zeit. Probanden der älteren Altersgruppe ($\geq$ 50 Jahre) benötigten bis zu etwa 35 % mehr Zeit als die jüngsten Probanden ($\leq$ 30 Jahre). Obwohl er keine Vorkenntnisse hatte, zeigte Proband P14

Tabelle 5.4 Probandenzuweisung zu den Aufnahmesessions und Umfang der Teilnahme an *Szenarien*, *Sonstiges* zwischen den Szenarien und *Gesamt*

ID	Aufnahme Session	Zeitlicher Umfang in [hh:mm:ss]									
		Auslagerung (Szenarien 1–3)			Einlagerung (Szenarien 4–6)			Opt. Durchlauf		Sonstiges	Gesamt
		1	2	3	4	5	6	7	8		
P01	1	00:18:15	00:19:20	00:18:39	-	-	00:15:51	00:23:42	00:14:34	00:10:59	02:01:19
P02	1	00:19:43	00:16:36	00:22:16	-	00:23:56	-	-	-	00:15:43	01:38:14
P03	1	00:24:41	00:25:07	00:09:34	00:27:04	-	-	-	-	00:03:11	01:29:37
P04	2	00:16:22	00:16:09	00:17:57	-	00:32:17	-	00:26:00	00:14:28	00:13:17	02:16:30
P05	2	00:25:47	00:20:05	00:19:11	-	-	00:26:36	-	-	00:08:42	01:40:22
P06	2	00:22:08	00:16:45	00:17:27	00:25:27	-	-	-	-	00:02:29	01:24:16
P07	3	00:20:13	00:23:38	00:16:16	-	00:26:40	-	-	-	00:15:16	01:42:02
P08	3	00:19:47	00:20:10	00:15:49	-	-	00:21:29	-	-	00:03:57	01:21:11
P09	3	00:18:18	00:16:33	00:18:05	00:27:40	-	-	00:23:47	00:15:57	00:05:03	02:05:24
P10	4	00:25:18	00:24:02	00:21:07	-	-	00:26:50	-	-	00:13:37	01:50:54
P11	4	00:17:13	00:34:10	-	00:33:30	-	-	-	-	00:08:20	01:33:13
P12	4	00:24:24	00:26:29	00:28:18	-	00:31:17	-	-	-	00:10:33	02:01:00
P13	5	00:22:28	00:19:11	00:20:07	-	-	00:24:08	-	-	00:02:59	01:28:53
P14	5	00:13:27	00:16:07	00:15:44	00:28:18	-	-	00:26:57	00:19:23	00:35:15	02:35:11
P15	5	00:27:55	00:24:44	00:25:14	-	00:29:57	-	-	-	00:07:26	01:55:17
P16	6	00:23:11	00:17:25	00:20:22	-	-	00:20:17	-	-	00:16:24	01:37:38
P17	6	00:18:42	00:19:59	00:15:45	00:24:08	-	-	-	-	00:02:08	01:20:41
P18	6	00:20:02	00:20:53	00:20:56	-	00:37:01	-	-	-	00:14:51	01:53:43
Min.		00:13:27	00:16:07	00:09:34	00:24:08	00:23:56	00:15:51	00:23:42	00:14:28	00:02:08	**01:20:41**
$\bar{x}$		00:21:00	00:20:58	00:18:59	00:27:41	00:30:11	00:22:32	00:25:06	00:16:05	00:10:34	**01:46:25**
Ges.		**06:17:54**	**06:17:22**	**05:22:46**	**02:46:07**	**03:01:08**	**02:15:11**	**01:40:26**	**01:04:21**	**03:10:10**	**31:55:26**

(32 Jahre) eine deutlich höhere Arbeitsgeschwindigkeit als der Durchschnitt: 36 % schneller in Szenario 1, 23 % schneller in Szenario 2 und 17 % schneller in Szenario 3. In den Szenarien 1 und 2 erzielte P14 nicht nur die schnellsten Bearbeitungszeiten, sondern führte die Aufgaben auch fehlerfrei aus. Die beiden langsamsten Probanden, P15 und P12, waren zum Zeitpunkt der Datenerfassung 43 Jahre alt. Das Gewicht zeigt eine leicht positive Korrelation mit der Bearbeitungszeit, während Größe und Geschlecht keinen relevanten Einfluss zu haben scheinen.

Technologische Kompetenz: Proband P14 zeigte in Szenario 2 eine starke Leistung bei der Bedienung des MDE-Geräts. Im Gegensatz dazu hatte Proband P11 Schwierigkeiten bei der Verwendung des MDE-Geräts und benötigte 00:34:10 Stunden, um Szenario 2 abzuschließen, was 63 % langsamer als der Durchschnitt war. Aufgrund von Zeitbeschränkungen konnte P11 nicht mit Szenario 3 fortfahren.

Durchgeführte Szenarien: Es war geplant, dass jeder Proband die Szenarien der Auslagerung 1 bis 3 sowie eine Aufgabe der Einlagerung aus den Szenarien 4, 5 oder 6 durchläuft. Vier der 18 Probanden absolvierten zusätzlich die Szenarien 7 und 8, was zu einer längeren Gesamtaufnahmedauer für diese Probanden führte.

Ungeplante Fehler: Bestimmte Probanden machten ungeplante Fehler, die sich auf ihre Bearbeitungszeiten auswirkten. Beispielsweise übersahen P03

und P11 die zweite und/oder dritte Seite der Pickliste, was zu unvollständigen Aufgaben des Kommissionierens und des Verpackens führte. Daraus ergaben sich verkürzte Bearbeitungszeiten für P03 in Szenario 3 (00:09:34 Stunden) und P11 in Szenario 1 (00:17:13 Stunden).

Warten: Die Kategorie *Sonstiges* (siehe vorletzte Spalte in Tabelle 5.4) umfasst Wartezeiten zwischen den Szenarien sowie Vorbereitungs- und Nachbereitungsaktivitäten zu Beginn und am Ende jeder Aufnahmesession. Während des Verpackens wurden die Probanden angewiesen, zu warten, wenn ein anderer Proband im Packbereich aktiv war. Sie warteten auch, wenn das erforderliche Gerät für die informationstechnische Führung von jemand anderem genutzt wurde. Dies führte zu absichtlich herbeigeführten Wartezeiten von bis zu mehreren Minuten (z. B. Proband P14 mit 00:35:15 Stunden).

Gewöhnungseffekt: Über die einzelnen Szenarien hinweg konnte ein Gewöhnungseffekt festgestellt werden. Die Arbeitsabläufe der Probanden schienen reibungsloser zu verlaufen, und die für ähnliche, wiederkehrende Aufgaben erforderliche Zeit verringerte sich sowohl bei der Einlagerung als auch bei der Auslagerung. In Szenario 8 benötigten die Probanden im Vergleich zu den vorherigen Szenarien 4–6 etwa 60 % weniger Zeit für die Einlagerung. Obwohl sich die Anzahl der zu kommissionierenden und zu verpackenden Positionen verdoppelte, stieg die Ausführungszeit für die Auslagerung von den Szenarien 1–3 bis zum Szenario 7 lediglich um etwa 24 % an. Dies deutet auf eine Anpassung an die erhöhte Aufgabenkomplexität hin.

Ermüdung: Während der Datenerfassung zeigten einige Probanden Anzeichen von Ermüdung, die sich in den Bearbeitungszeiten ihrer letzten Szenarien widerspiegelten. Während Proband P14 in den Szenarien 1–3 die schnellsten Zeiten verzeichnete, war in den Szenarien 7 und 8 ein deutlicher Leistungsabfall zu beobachten. Im Vergleich zu den anderen Probanden war P14 in beiden Szenarien der Langsamste und benötigte in Szenario 8 22 % mehr Zeit als der nächstlangsamste Proband. Diese Ergebnisse deuten darauf hin, dass die Ermüdung möglicherweise auf längere Aufnahmesessionen aufgrund von Wartezeiten und das hohe Arbeitstempo während der ersten Szenarien zurückzuführen ist.

Schritt 28: Datenaufbereitung

Nach dem Datenexport wurden die Videostreams der mobilen und stationären Kameras manuell anhand visueller und auditiver Merkmale synchronisiert. Als visuelle Referenzen dienten schnelle Bewegungen der Probanden (insbesondere Gehbewegungen) in Kombination mit den weißen Bodenmarkierungen sowie eine Atomuhr auf einem Tablet als globaler Zeitstempel.

Schritt 29: Annotation

Abbildung 5.13 veranschaulicht die Komplexität des Annotationsprozesses und die daraus resultierenden Labeldarstellungen. Das Beispiel zeigt einen ca. 46,6 Sekunden langen (1.398 Frames) Kommissionierprozess von Proband P14 während des Szenarios 2 der Aufnahmesession 5. Die zwei Pickpositionen umfassen jeweils den eindimensionalen Weg von der Basis zum Artikel, das manuelle Entnehmen des Artikels aus einem Fachbodenregal, das Scannen der Barcodes des Lagerfachs und des Artikels, die Quittierung der Entnahme mittels des MDE-Geräts, den Transport des Artikels zurück zur Basis und das Ablegen auf dem Kommissionierwagen.

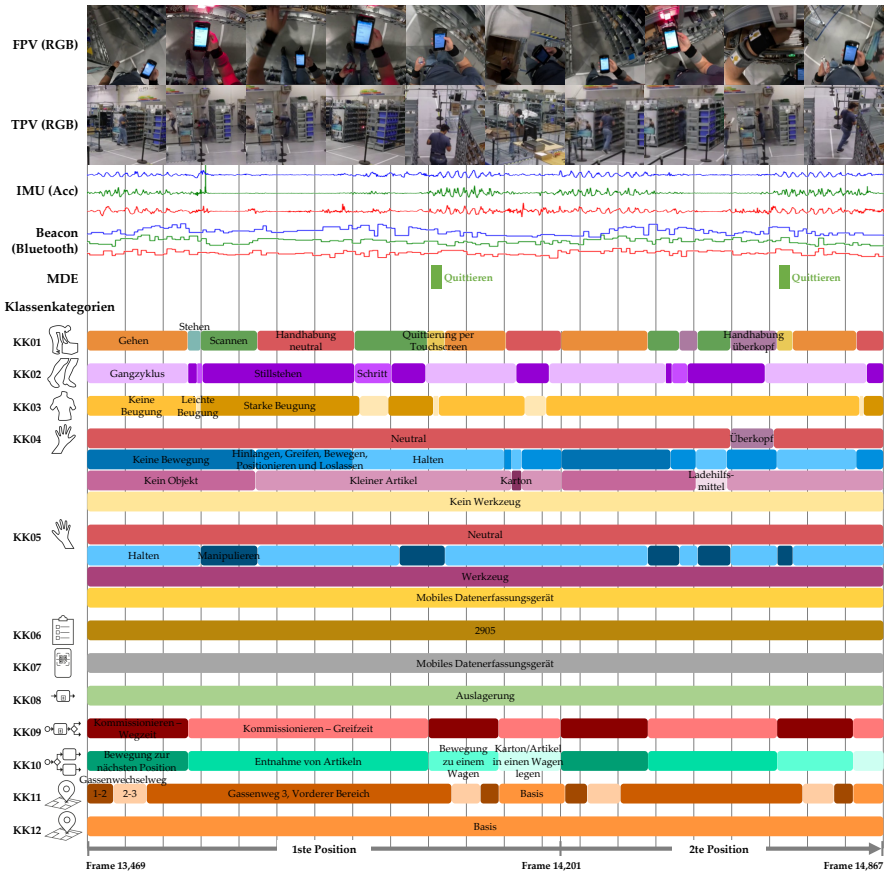


Abb. 5.13 Exemplarische Sequenz annotierter Labels des DaRA-Datensatzes (angelehnt an [Yos+24])

Die ersten vier Ebenen der Abbildung 5.13 zeigen Sensordaten, darunter der FPV des Probanden, Ausschnitte aus fünf der sechs TPV, die Energie der Trägheitsaufzeichnungen von einem IMU-Set 44-C (blau = rechtes Handge-

lenk, grün = Gürtel, rot = linkes Handgelenk) und RSSI vom gleichen Geräteset, das mit dem Beacon Nr. 13 verbunden ist (Position des Beacons siehe Abbildung 5.7). Die fünfte Ebene zeigt zwei vom MDE-Gerät übermittelte und im WMS gespeicherte Quittierungen der Entnahme. Die nachfolgenden Ebenen zeigen die 12 Klassenkategorien mit ihren annotierten Labels, wobei ein Label einiger Kategorien (z. B. *Auftrag* (KK06)) die gesamte Sequenz umfasst, während andere (z. B. *Teilaktivität - Beine* (KK02)) mehrere Annotationssegmente mit unterschiedlichen Labels enthalten. Ein Video dieser Sequenz ist auf YouTube[1] verfügbar.

In den ersten Frames von Abbildung 5.13 beginnt der Proband mit der Kommissionierung der ersten Pickposition, indem er den Gassenwechselweg entlang zur nächsten Pickposition in den dritten Gassenweg geht, dabei ein MDE-Gerät in der rechten Hand hält und die linke Hand weder ein Objekt hält noch nach einem greift. Dieser Arbeitsschritt ist dem Teilprozess *Wegzeit* und dem Grobprozess *Auslagerung* zuzuordnen. Der Kommissionierwagen verweilt während des Prozesses auf der Basis.

Als der Proband das Regal der Pickposition erreicht hatte, blieb er stehen und suchte nach dem richtigen Fach, wobei er auf dem Touchscreen die zu entnehmende Menge überprüfte. Die Bewegung *Starke Beugung* begann mit dem Scannen des Codes des Lagerfaches. Der Beginn der Beugungsbewegung ist in den IMU-Daten des Torsos (siehe die grüne Linie in Abbildung 5.13) als deutlicher Peak erkennbar. Zusätzliche Bewegungssegmente und ihre entsprechenden Labels lassen sich ebenfalls visuell in den IMU-Signalen identifizieren – insbesondere die Labels der Bein-Klassenkategorie (KK02). Segmente des *Gangzyklus* sind durch rhythmische Schwingungen im Torso der IMU-Daten (siehe grüne Linie) gekennzeichnet, während die Signalamplitude während *Schritte* unregelmäßiger wird und deutlich abnimmt und beim *Stillstehen* eine gerade Linie ergibt.

Schritt 30: Revision

Im Anschluss an die Annotation wurden sowohl manuelle als auch automatisierte Revisionen der annotierten Labels durchgeführt (siehe Datensatztaxonomie in Tabelle A.1). Bei der manuellen Revision wurde jede annotierte Datei zusammen mit den Videodateien in das Annotationstool SARA importiert (Beispiel siehe Abbildung 5.12).

Jede Datei wurde einmal (mit Ausnahme der Dateien der *Hauptaktivität*) von einem der acht Revisoren überprüft. Bei falschen Labels oder falsch platzierten Segmenten wurden neue Labels zugewiesen oder die Start- und Endgrenzen der Segmente angepasst.

Die *Hauptaktivität* (KK01) wurde im Gegensatz zu den anderen Klassenkategorien nicht separat, sondern parallel zur Annotation der *Teilaktivitäten*

[1] https://youtu.be/qU0XvKY20SE

KK02–KK05 revidiert. Zu diesem Zweck wurden die bereits annotierten Klassenlabels der Hauptaktivität um die Klassenlabels von KK02 erweitert. Das Ziel war es, die bestehenden Segmente der Hauptaktivität beizubehalten, da sie semantisch eng mit den Teilaktivitäten verbunden sind. Während der Annotation von KK02 untersuchte der Annotator die Hauptaktivität und korrigierte sie bei Bedarf manuell. Aufgrund der Verwendung von Labelabhängigkeiten im Annotationstool erforderten die falsch annotierten Labels der Hauptaktivität eine Anpassung, um die KK02-Klassenlabels zuzuweisen. Es war etwa nicht möglich, *Gangzyklus* (KL016) als Teilaktivität der Beine zu annotieren, wenn *Stehen* (KL012) bereits innerhalb desselben Segments als Hauptaktivität zugewiesen war. Dieses Verfahren wurde analog für KK03 bis KK05 wiederholt, wobei die überarbeiteten Labels für die Hauptaktivitäten kontinuierlich übernommen wurden.

Weiterhin wurden automatisierte Plausibilitätsprüfungen durchgeführt. Diese dienten dazu, Frames mit einer übermäßigen oder unzureichenden Anzahl von Labels zu identifizieren, wobei die zulässige Anzahl je nach Klassenkategorie variiert. Weiterhin wurden einander ausschließende Labelsequenzen erkannt. Dies betrifft sowohl Sequenzen innerhalb einer einzelnen Klassenkategorie als auch Sequenzen über mehrere Kategorien hinweg. So folgt beispielsweise in den Klassenkategorien der *Lokalisierung* (KK11 und KK12) das Label *Gassenweg* (KL163 und KL190) nicht direkt auf *Wagenbereich* (KL156 und KL183), da sich dazwischen weitere Bereiche befinden, die zuvor durchlaufen werden.

Wenn alle Kategorien kombiniert werden, ergeben sich aus den revidierten Labels 68.187 einzigartige Labelrepräsentationen. Für alle Klassenkategorien erforderten die Annotation 1.572 und die Revision 361 Arbeitsstunden (siehe Tabelle 5.5). Der Zeitaufwand bezieht sich auf die Hauptannotation und -revision von 3.444.327 Frames des 31:55:26 Stunden Videomaterials. Das Aufwandsverhältnis in Tabelle 5.5 gibt den durchschnittlichen Zeitaufwand an, der für die Annotation oder Revision von einer Minute Videomaterial benötigt wird. Er variierte erheblich zwischen den verschiedenen Klassenkategorien. Im Falle der Annotation reichte der durchschnittliche Aufwand für das Labeln eines einminütigen Videos von 6 Sekunden (*Auftrag*, *Hardware für die informationstechnische Führung* und *Grobprozess* (KK06–KK08)) bis zu über 12 Minuten (*Teilaktivität - Linke Hand* (KK04)). Die Zeiten für die Schulung der Annotatoren, Testannotationen oder die Korrektur von Fehlern, die durch automatisierte Prüfungen identifiziert wurden, sind in der Tabelle nicht berücksichtigt.

Schritt 31 und 32: Sensordaten- und Labelqualität

Zur Evaluation des Datensatzes wurden die Qualität der eingesetzten Sensoren bewertet, die Labelqualität mittels κ-Werten bestimmt und das Zusammenspiel von Sensordaten und Labels anhand einer HAR-Anwendung unter

Tabelle 5.5 Annotation- und Revisionsaufwand je Klassenkategorie

Klassenkategorie		Annotation		Revision	
ID	Name	Gesamt	Verhältnis	Gesamt	Verhältnis
		[hh:mm:ss]			
KK01	Hauptaktivität	172:35:30	0:05:24	-	-
KK02	Teilaktivität - Beine	278:44:27	0:08:44	68:12:31	0:02:08
KK03	Teilaktivität - Torso	108:12:37	0:03:23	76:13:01	0:02:23
KK04	Teilaktivität - Linke Hand	384:24:34	0:12:02	71:15:00	0:02:14
KK05	Teilaktivität - Rechte Hand	378:12:41	0:11:51	73:46:51	0:02:19
KK06	Auftrag				
KK07	Hardware für die informationstechnische Führung	3:13:20	0:00:06	1:01:40	0:00:02
KK08	Grobprozess				
KK09	Teilprozess	129:15:32	0:04:03	39:20:41	0:01:14
KK10	Feinprozess				
KK11	Lokalisierung - Mensch	92:08:38	0:02:53	22:51:42	0:00:43
KK12	Lokalisierung - Kommissionierwagen	25:19:00	0:00:48	8:30:55	0:00:16
Gesamt	**Alle Kategorien**	**1572:06:19**	**0:49:15**	**361:12:21**	**0:11:19**

Berechnung des F1-Maßes bestimmt. Die Datensatzevaluation ist Teil der übergeordneten Evaluation und wird daher in Abschnitt 6.2 näher behandelt.

5.1.6 Phase 6 | Veröffentlichung des Datensatzes

Schritt 33 bis 36: Datenveröffentlichung, Klarheit der Datenstruktur, Vorverarbeitungsskript und Datenbeschreibung veröffentlichen

Im Einklang mit den FAIR-Prinzipien [Wil+16] wurden die Daten auf Zenodo veröffentlicht [Nie+26b; Nie+26c]. Mittels veröffentlichter Pythonskripte lassen sich die synchronisierten Daten reproduzieren und die Annotationsergebnisse anwendungsspezifisch anpassen, um individuelle Informationen zu extrahieren [RA25].

Die Beschreibung [Nie+26a] und die Dokumentation [Nie+26b] des Datensatzes orientieren sich an dem von Gebru [Geb+21] vorgeschlagenen Vorgehen zur standardisierten Dokumentation von Datensätzen. Die Dokumentation des DaRA-Datensatzes umfasst

- eine Annotationsrichtlinie,
- detaillierte Beschreibungen aller Klassenkategorien und Klassenlabels,
- eine Beschreibung der Annotations- und Sensordateien,
- die Artikelstammdaten (siehe Abschnitt A.1.3),
- eine visuelle Dokumentation gehandhabter Artikel (siehe Abschnitt A.1.4),
- die Kundenaufträge als Listen (siehe Abschnitt A.1.5),
- die Sensorpositionen,
- Angaben zur Synchronisation von Sensordaten und Annotationen sowie
- Informationen zum zeitlichen Ablauf der Szenarien (siehe Abschnitt A.1.6).

5.2 Konzeptuelle und empirische Fundierung der Prozesserkennung

In den folgenden Abschnitten wird die Verwendung des DaRA-Datensatzes (siehe Abschnitt 5.1) für die Evaluation der entwickelten Prozesserkennungsmethoden (siehe Abschnitt 4.2) erläutert und schrittweise an das experimentelle Design der Prozesserkennung herangeführt. Ausgangspunkt bildet die Beschreibung der Prozessebenen und ihrer Labels. In den beiden darauffolgenden Abschnitten werden die Zusammenhänge zwischen den Prozessebenen und anderen Klassenkategorien des Datensatzes aufgezeigt.

5.2.1 Beschreibung der Prozessebenen und ihrer Labels

Die Klassenkategorien der Prozesse des DaRA-Datensatzes sind in drei Ebenen unterteilt: **Grob-** (KK08), **Teil-** (KK09) und **Feinprozess** (KK10) (Liste aller Klassenkategorien und Klassenlabel siehe Abschnitt 5.1.4). Sie unterscheiden sich hinsichtlich der Labelgranularität, wobei eine inhaltliche Verknüpfung zwischen den einzelnen Komponenten besteht (siehe Abbildung 5.14).

In Bezug auf die **Grobprozesse** wird der überwiegende Anteil der annotierten Segmente mit 68,4 % von dem Label *Auslagerung* (KL110) dominiert. Obwohl die Aufträge mit den gleichen Artikeln aus- und eingelagert wurden, nimmt die *Einlagerung* (KL111) mit 30,2 % einen deutlich geringeren zeitlichen Umfang ein. Ein möglicher Erklärungsansatz für dieses Phänomen liegt darin, dass die Probanden während der Einlagerung einen der Aufträge 2904, 2905 und 2906 gleichzeitig dreimal einlagerten, während bei der Auslagerung jeder Proband jeden der Aufträge einmal einzeln auslagerte. Weitere Grobprozesse spielen mit 1,5 % (*Anderer Grobprozess*, (KL112)) eine untergeordnete oder mit 0 % (*Grobprozess unbekannt*, (KL113)) keine Rolle.

Eine Differenzierung der Grobprozesse erfolgt in mehrere **Teilprozesse**. Sowohl bei der Auslagerung als auch bei der Einlagerung ist eine ausgewogene Verteilung zwischen Greif- (KL116 und KL120), Weg- (KL115 und KL119) und Verpackungs- (KL118) bzw. Auspacktätigkeiten (KL117) zu erkennen (Auslagerung: 20,3 %, 18,9 % und 19,4 %; Einlagerung: 8,7 %, 7,1 % und 9,2 %). Die Vorbereitung und das Abschließen der Aufträge nehmen deutlich weniger Zeit in Anspruch, wobei *Auftrag vorbereiten* (KL114) mit 9,9 % fast doppelt so viel Zeit einnimmt wie *Auftrag abschließen* (KL121) mit 5,0 %. Grund für den großen Unterschied ist die Wartezeit, welche teilweise in der Auftragsvorbereitung auftrat, während die Probanden auf die Hardware wie MDE-Gerät oder Handschuhscanner warteten.

Auf der Ebene der **Feinprozesse** zeigt sich eine starke Fragmentierung der Tätigkeiten bei gleichzeitig klar erkennbaren Zeittreibern. Den größten Anteil machen die Labels *Entnahme von Artikeln* (KL139, 15,6 %) und *Bewegungen zur nächsten Position* (KL137, 14,3 %) aus. Auffällig sind vergleichsweise hohe *Wartezeiten* (KL134) von 8,5 %, die überwiegend während der Teilprozesse

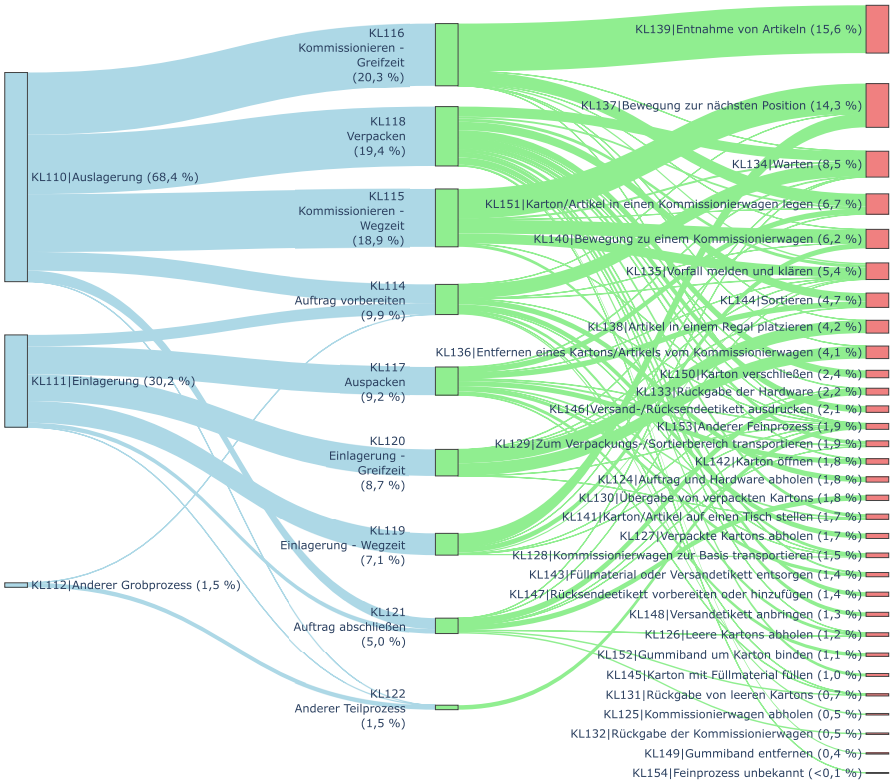


Abb. 5.14 Sankey-Diagramm zur Darstellung der mengenproportionalen Klassenlabelverbindungen zwischen den drei Prozessebenen Grobprozess (links), Teilprozess (mittel) und Feinprozess (rechts) aller Probanden. Die prozentualen Angaben beziehen sich auf den Anteil der annotierten Frames eines jeweiligen Klassenlabels innerhalb dessen Prozessebene.

Verpacken und *Auftrag vorbereiten* auftreten. Diese Warteanteile deuten auf organisatorische oder technische Unterbrechungen hin. Weitere Feinprozesse mit Anteilen über 5 % sind das *Ablegen von Kartons oder Artikeln in Kommissionierwagen* (KL151), die *Bewegungen zum Kommissionierwagen* (KL140) sowie das *Melden und Klären von Vorfällen* (KL135), die kumulativ einen relevanten Zeitanteil einnehmen. Die folgenden sechs Feinprozesse liegen zwischen 2 % und 5 %, während die übrigen 19 jeweils unter 2 % bleiben.

5.2.2 Klassenkategorische Hierarchie der Prozesserkennung

Das Konzept der Prozesserkennung lässt sich anhand einer sprachlichen Analogie im Zusammenhang mit der HAR und der HCR verdeutlichen (siehe Abbildung 5.15). Auf der untersten Ebene entsprechen die von HAR identifizierten **Haupt-** (KK01) und **Teilaktivitäten** (KK02-KK05) einzelnen **Wörtern**. Teilaktivitäten wie *Gangzyklus* (KL016), *linke Hand hält einen Kommissionier-*

wagen (KL036 und KL045), *rechte Hand hält einen Kommissionierwagen* (KL071 und KL080) oder *Torso nicht gebeugt* (KL024) beschreiben die motorische Ausführung einer Handlung. Die Aggregation mehrerer Teilaktivitäten bildet eine Hauptaktivität, etwa das *Schieben eines Kommissionierwagens* (KL007), die auf der Wortebene bleibt und noch keine abgeschlossene oder zielgerichtete Handlung darstellt.

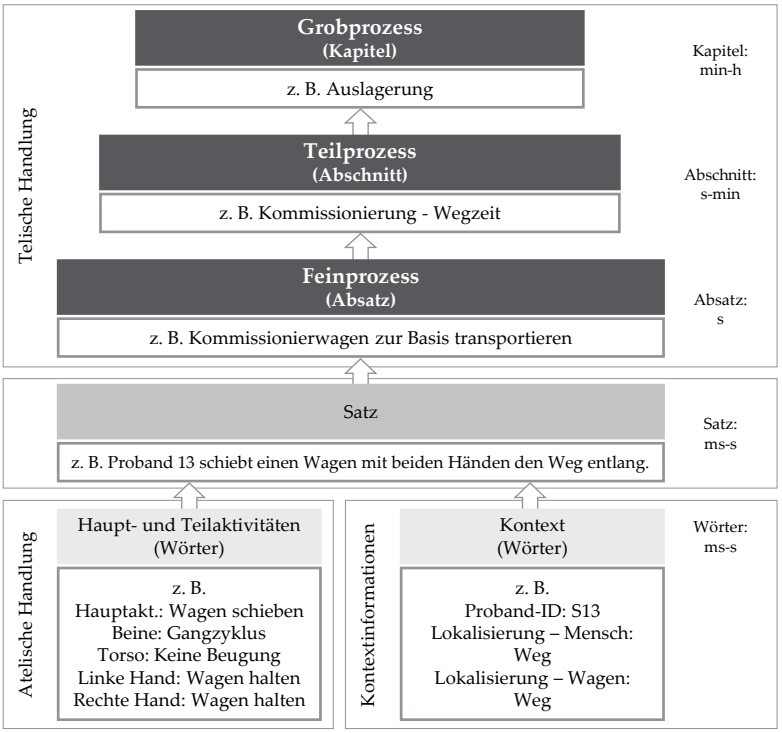


Abb. 5.15 Klassenkategorische Hierarchie der aktivitäts- und kontextsensitiven Prozesserkennung

Parallel dazu entsprechen auch die von HCR bereitgestellten **Kontextinformationen** – wie Proband-ID sowie Lokalisierungsangaben von Proband und Kommissionierwagen (z. B. *Weg*, KL161) – **Wörtern** und liefern semantische Informationen darüber, *wer*, *wo* und *unter welchen Bedingungen* eine Aktivität ausgeführt wird. Die Integration von aktivitätsbezogenen und kontextbezogenen Wörtern ergibt einen **Satz**, der eine konkrete Handlungsinstanz im Kontext darstellt. Ein Beispiel für einen solchen Satz ist: *Proband* 13 *schiebt einen Wagen mit beiden Händen den Weg entlang*.

Mehrere Sätze werden zu einem **Absatz** zusammengefasst, der einem **Feinprozess** entspricht. Ein Feinprozess stellt eine kurze, zielgerichtete Aktionssequenz mit einem klar definierten Endzustand dar, wie *Kommissionierwagen zur Basis transportieren* (KL128). Mehrere Feinprozesse werden weiter

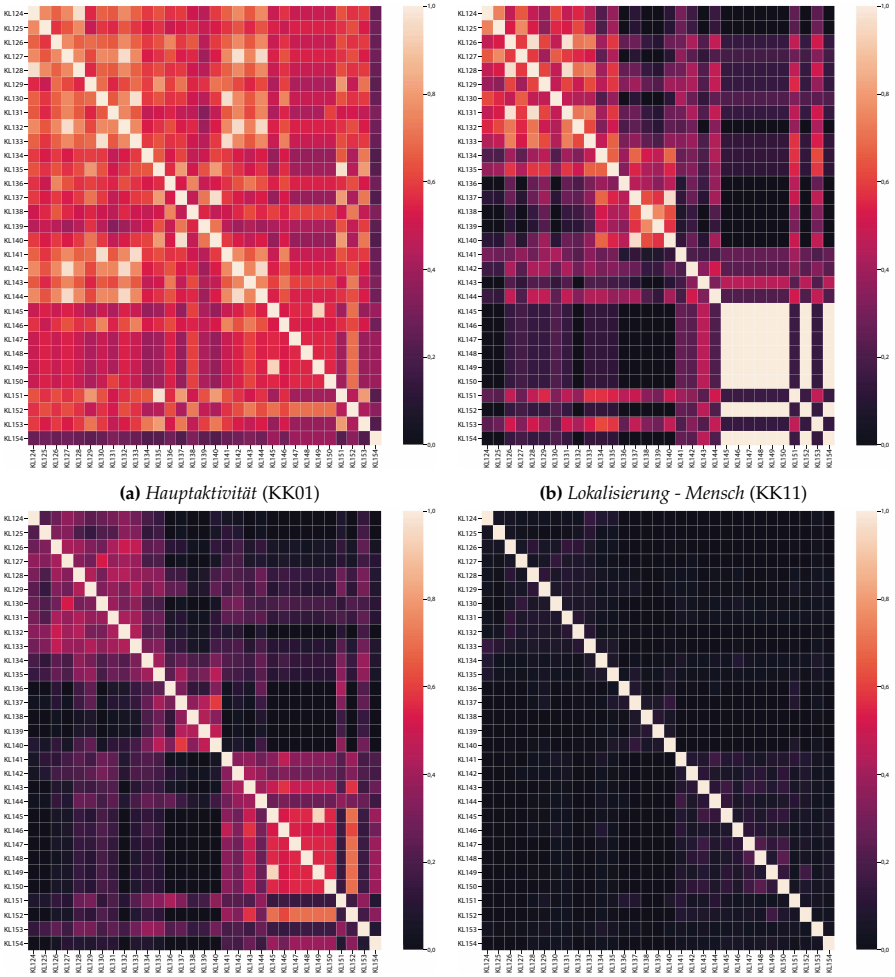
zu einem **Teilprozess** kombiniert, der mit einem **Abschnitt** vergleichbar ist. Ein Beispiel für einen Teilprozess ist die *Wegzeit* im Rahmen der *Kommissionierung* (KL115), die mehrere transportbezogene Feinprozesse umfasst. Schließlich bildet die Zusammenfassung mehrerer Teilprozesse einen **Grobprozess**, der einem **Kapitel** entspricht, wie die *Auslagerung* (KL110), die einen vollständigen logistischen Prozess darstellt.

Diese hierarchische Strukturierung ermöglicht eine klare **Unterscheidung** zwischen **Aktivitäten**, **Kontext** und **Prozessen**. Während der Kontext einen Zustand beschreibt, werden Aktivitäten auf Wort- und Satzebene als **atelisch** betrachtet, da sie fortlaufende oder situationsgebundene Handlungen ohne inhärenten Endpunkt beschreiben. Im Gegensatz dazu werden Prozesse auf Absatzebene und darüber als **telische Handlungen** verstanden, da sie durch ein inhärentes Ziel und einen klar definierten Endzustand gekennzeichnet sind. Folglich bietet die Prozesserkennung die notwendige semantische Abstraktionsebene, um Ist-Zeitdaten in einer für die ergonomische Analyse und das Zeitmanagement aussagekräftigen Weise auszuwerten.

5.2.3 Korrelation zwischen Aktivitäten, Kontext und Prozessen

Grundvoraussetzung für die Erkennung von Prozessen nach dem Vorbild der Hierarchie aus Abschnitt 5.2.2 ist eine statistisch signifikante, wechselseitige Beziehung zwischen Prozessen und Bewegungs- sowie Kontextinformationen. Analysen der annotierten Klassenlabels des DaRA-Datensatzes zeigen diese klare Korrelation. Die in Abbildung 5.16 (a)–(d) dargestellten Korrelationen für die Klassenkategorie **Feinprozess** (KK10) dienen als exemplarischer Ausschnitt; vergleichbare Analysen wurden auch für weitere Prozessebenen und Klassenkategorien durchgeführt. Zur Quantifizierung und Visualisierung der Korrelationen werden Konfusionsmatrizen verwendet, wobei sowohl die X- als auch die Y-Achse die Klassenlabels der Klassenkategorie Feinprozess darstellen. Die Farbintensität der einzelnen Zellen dient als Maß für den Grad der Übereinstimmung zwischen zwei Prozessklassenlabels in Abhängigkeit von den jeweils verwendeten Inputklassenkategorien. Je dunkler eine Zelle dargestellt ist, desto geringer fällt die Übereinstimmung aus. Ziel ist eine geringe Gesamtübereinstimmung, bei der ausschließlich die Diagonale eine hohe Übereinstimmung aufweist.

Wie in Abbildung 5.16 (a) dargestellt, werden die Klassenlabels der Klassenkategorie **Hauptaktivität** (KK01) zur Repräsentation der Feinprozesse herangezogen. Der Mittelwert der Übereinstimmung aller betrachteten Prozesspaare beträgt 57 %. Daraus ergibt sich, dass eine automatische Erkennung von Feinprozessen auf Basis ausschließlich der Hauptaktivitäten nur eine geringe Erkennungsleistung aufweist. So zeigen etwa die Klassenlabels *Bewegung zur nächsten Position* (KL137) und *Bewegung zu einem Kommissionier-*



(a) *Hauptaktivität* (KK01)

(b) *Lokalisierung - Mensch* (KK11)

(c) *Hauptaktivität* (KK01) und *Lokalisierung - Mensch* (KK11)

(d) *Hauptaktivität* (KK01), *Lokalisierung - Mensch* (KK11), *Teilaktivität - Linke Hand* (KK04) und *Teilaktivität - Rechte Hand* (KK05)

Abb. 5.16 Korrelation zwischen den Klassenlabels KL124 bis KL154, der Klassenkategorie *Feinprozess* (KK10) und ausgewählten Klassenkategorien, dargestellt in den Subabbildungen (a)–(d)

wagen (KL140) eine Übereinstimmung von 93 % auf. Diese nahezu identische Repräsentation ist darauf zurückzuführen, dass in beiden Klassenlabeln die Hauptaktivität *Gehen* (KL011) dominiert.

Wenn jedoch **Lokalisierung - Mensch** (KK11) als einzige Klassenkategorie verwendet wird (Abbildung 5.16 (b)), reduziert sich die durchschnittliche Übereinstimmung auf 34 %. Dennoch ist für das obige Beispiel immer noch eine hohe Übereinstimmung von 95 % zu beobachten. Der Grund für dieses Phänomen liegt darin, dass beide Prozesse in Bezug auf die räumliche

Verteilung dieselben oder fast identische Zonen durchlaufen, was zu einer erheblichen Überschneidung in Bezug auf die kontextuelle Relevanz führt. Gleiches gilt auch für die Prozessklassenlabels KL145 bis KL150, welche in derselben Zone stattfinden.

Die Konfusionsmatrix in Abbildung 5.16 (c) zeigt die Übereinstimmungen der Feinprozesse auf Basis der Kombination der Klassenkategorien **Hauptaktivität** (KK01) und **Lokalisierung - Mensch** (KK11). Im Vergleich zu den Matrizen (a) und (b), die nur eine Klassenkategorie als Input umfassen, ist in diesem Fall eine deutlich geringere durchschnittliche Übereinstimmung zu erkennen. Die Matrix bestätigt quantitativ, dass die Feinprozesse bei Verwendung beider Klassenkategorien deutlich besser voneinander unterschieden werden, was durch den Gesamtwert von weniger als 19 % belegt wird.

Die Matrix (c) weist keine vorherrschende Diagonalstruktur auf. Stattdessen sind die Übereinstimmungen relativ gleichmäßig über die Matrix verteilt, wobei die meisten Zellen niedrige Werte aufweisen. Aus Sicht der Prozesserkennung ist dieses Muster wünschenswert, da es darauf hindeutet, dass verschiedene Prozesse selten ähnliche Bewegungs- und Kontextmuster aufweisen und daher weniger wahrscheinlich miteinander verwechselt werden.

Gleichzeitig gibt es vereinzelte Fälle, in denen die Ähnlichkeit zwischen Prozessen mit verwandten Inhalten zunimmt. Diese verbleibenden Ähnlichkeiten sind zu erwarten, da bestimmte grundlegende Bewegungen (z. B. *Handhabung* (KL008–KL010) oder *Gehen* (KL011)) auch in verschiedenen Prozessen in denselben Zonen vorkommen. Es ist jedoch unbedingt sicherzustellen, dass diese Ähnlichkeiten nicht systematisch auftreten, sondern auf eine ausgewählte Anzahl logisch erklärbarer Prozesspaare beschränkt sind.

Die Ergebnisse der Konfusionsmatrix Abbildung 5.16 (c) zeigen, dass die Integration von **Hauptaktivität** (KK01) und **Lokalisierung - Mensch** (KK11) ein hohes Maß an Selektivität zwischen Feinprozessen ermöglicht. Im Gegensatz zu Konfigurationen mit nur einer Klassenkategorie weist die durchschnittliche Übereinstimmungsrate einen deutlichen Rückgang auf, wodurch Prozesse robuster und eindeutiger erkannt werden.

Während eine Erhöhung der Anzahl der Klassenkategorien (z. B. ergänzende **Hand**informationen (KK04 und KK05), wie in Abbildung 5.16 (d) dargestellt) die Übereinstimmung weiter verringert (3,28 %), geht dies mit einer Zunahme der Komplexität der Labelrepräsentationen einher. Es hat sich gezeigt, dass diese zunehmende Granularität den erforderlichen Daten- und Annotationsaufwand erheblich erhöht. Folglich ist es bei der Modellierung von HCR-Systemen für die Prozesserkennung unerlässlich, ein Gleichgewicht zwischen Prozessselektivität und Annotationsaufwand zu finden. Die in Abbildung 5.16 (c) dargestellten Ergebnisse zeigen, dass die Integration von Hauptaktivität und Lokalisierung bereits ein Aufwand-Nutzen-Verhältnis bietet, das der zuverlässigen Erkennung von Feinprozessen förderlich ist.

Kapitel 6
Evaluationen

Zusammenfassung Das sechste Kapitel evaluiert den Gesamtansatz der Arbeit bestehend aus Framework zur Datensatzerstellung, DaRA-Datensatz und dem Verfahren zur Prozesserkennung. Die Evaluation zeigt, dass das entwickelte Framework eine strukturierte Erstellung von HAR-Datensätze ermöglicht und eingeschränkt in verwandten Forschungsbereichen anwendbar ist. Die Analyse des DaRA-Datensatzes bestätigt eine hohe Labelqualität und damit seine Eignung als Grundlage für weiterführende Untersuchungen. Auf dieser Basis zeigt die Evaluation der Prozesserkennung, dass sich Arbeitsprozesse bereits aus reduzierten Aktivitäts- und Lokalisierungsinformationen ableiten lassen. Während Teilprozesse zuverlässig erkannt werden, nimmt die Genauigkeit bei feineren Prozessschritten ab. Insgesamt belegen die Ergebnisse, dass die menschliche Aktivitätserkennung über die reine Bewegungsanalyse hinaus zur strukturierten Analyse intralogistischer Arbeitsprozesse dient und somit eine automatisierte Auswertung im Sinne arbeitswissenschaftlicher Zeitstudien grundsätzlich realisierbar ist.

Dieses Kapitel basiert teilweise auf den folgenden Veröffentlichungen:

Friedrich Niemann u. a. „Towards Standardized Dataset Creation for Human Activity Recognition: Framework, Taxonomy, Checklist, and Best Practices“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_5

Friedrich Niemann u. a. „DaRA Dataset: Combining Wearable Sensors, Location Tracking, and Process Knowledge for Enhanced Human Activity and Human Context Recognition in Warehousing“. In: *Sensors* (2026). DOI: 10.3390/s26020739

Friedrich Niemann u. a. *Test Annotations for Quality Evaluation of the DaRA Dataset – Annotated and Revised Video Data with Activity and Context Labels*. 2026. DOI: 10.5281/ZENODO.15118021

Fernando Moya Rueda u. a. „Activity- and Context-Sensitive Recognition of Human-Centered Processes in Warehousing“. In: *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2026)*. Status: eingereicht. Italien, 2026

6.1 Umfragebasierte Evaluation der Methode zur Datensatzerstellung

Die Evaluation der Methode zur Datensatzerstellung erfolgt in drei Schritten. Die Anwendbarkeit der in Abschnitt 4.3.7 entwickelten Checkliste wird anhand einer Umfrage unter Autoren von HAR-Benchmark Datensätzen, durch die Überprüfung ihrer Übertragbarkeit auf HAR-verwandte Forschungsbereiche sowie aus unternehmerischer Perspektive bewertet.

6.1.1 Umfrage zur Checkliste

Zur Evaluation der Vollständigkeit und praktischen Anwendbarkeit der Checkliste wurde eine retrospektive Analyse bestehender Datensätze auf Basis einer Selbstbewertung durch die jeweiligen Autoren durchgeführt. Im Rahmen einer Onlineumfrage wurden den Autoren die in der Checkliste definierten Kriterien vorgelegt und sie wurden gebeten, diese zur Klassifikation des Erstellungsprozesses ihres Datensatzes heranzuziehen. Weiterführende Erläuterungen, wie sie in Abschnitt 4.3 enthalten sind, standen während der Umfrage nicht zur Verfügung.

An der Umfrage beteiligten sich die Autoren von acht Benchmark Datensätzen:

- *HDM05* [HDM05; Mül+07]: oMoCap-Daten zu Fortbewegung, statischen Körperhaltungen und Sport
- *HDM12 Dance* [VK12; VK16]: Argentinische Tangosequenzen, aufgeführt von elf Tanzpaaren
- *HuGaDB* [CK18; HuGaDB18]: Bewegungs- und Haltungsaktivitäten für die Ganganalyse und Aktivitätsanalyse
- *UMAFall* [CA18; CSC17]: Tägliche Aktivitäten und Stürze für die Sturzfallerkennungsforschung
- *LARa* [Nie+20a; Nie+20c]: Verpackungs- und Kommissioniertätigkeiten, die mit Klassen und Attributen gelabelt sind
- *OpenPack* [OpenPack22; Xia+25; Yos+24]: Verpackungsdaten, die über IMUs, RGB- und Tiefenkameras aufgezeichnet wurden
- *CAARL* siehe Abschnitt 4.1 [Nie+21a; Nie+21b]
- *DaRA* siehe Abschnitt 5.1 [Nie+26a; Nie+26b]

Die Ergebnisse der Umfrage (siehe Tabelle 6.1) demonstrieren eine heterogene Implementierung der empfohlenen Schritte. Obwohl insbesondere in den Phasen der Datensatzvorbereitung und Datenaufnahme gewisse Gemeinsamkeiten festzustellen sind, lässt sich trotz zunehmender Reife des Forschungsfeldes konstatieren, dass kein einheitlich standardisiertes Verfahren zur Datensatzerstellung vorliegt. Defizite treten insbesondere in der Vorbereitung der Datenaufnahme sowie in der Durchführung der Datenverarbeitung auf, insbesondere bei der Annotation und Revision. Eine unzureichende

Dokumentation hat eine Beeinträchtigung der Transparenz und Reproduzierbarkeit zur Folge. Dies verdeutlicht den Bedarf an klar definierten Richtlinien für die Entwicklung und Überarbeitung von HAR-Datensätzen.

Trotz der aufgeführten Heterogenität werden alle in der Checkliste enthaltenen Kriterien grundsätzlich berücksichtigt oder als relevant erachtet. Die vorliegende Evidenz stützt die Hypothese, dass die Checkliste als strukturiertes Framework für die systematische Erstellung von HAR-Datensätzen eine hohe praktische Anwendbarkeit aufweist. Insbesondere für Forscher, die neu in diesem Bereich sind, bietet die Checkliste eine Orientierungshilfe für den gesamten Entwicklungsprozess, von der Planung bis zur Veröffentlichung. Es wurde jedoch auch deutlich, dass die Zusammenfassung einzelner Schritte in einzeiligen Beschreibungen zu unterschiedlichen Interpretationen führt. Es wird daher empfohlen, bei der Anwendung der Checkliste die detaillierten Beschreibungen in Abschnitt 4.3 heranzuziehen. Die tabellarische Bewertung durch die Datensätze fungiert in diesem Zusammenhang weniger als vergleichender Qualitätsmaßstab der Datensätze, sondern vielmehr als Mittel zur Bewertung der Checkliste selbst.

Tabelle 6.1 Umfrageergebnisse zur Checkliste (siehe Tabelle 4.18). In den letzten acht Spalten bewerten die Autoren ihre Datensätze retrospektiv nach den Kriterien der Datensatzerstellung auf einer Skala von ○ (nicht erfüllt) bis ● (vollständig erfüllt).

Checkliste für jeden Schritt des Frameworks		Umfrageergebnisse							
		HDM05	HDM12	HuGaDB	UMAFall	LARa	OpenPack	CAARL	DaRA
Planung der Datensatzerstellung									
1	Definieren Sie den *Nutzen* und den *Zweck* des Datensatzes.	●	◕	●	◕	●	◕	●	●
2	Legen Sie vor Beginn den *Umfang* (Länge und Menge) der Aufnahme fest.	●	◕	○	◕	◕	◕	●	●
3	Bestimmen Sie die *Aufnahmeumgebung*.	●	●	●	◕	●	●	●	●
4	Definieren Sie die *Szenarien* klar.	●	◑	●	◕	◑	●	◕	●
5	Wählen Sie die zu verwendenden *Sensoren* (Typ, Anzahl, Positionierung) aus.	●	●	●	●	●	●	●	●
6	Erstellen Sie eine *Probandeninformation* zur der Studie, den Aufnahmen und der Verwendung der Daten.	○	●	○	◕	◑	●	●	●
7	Bereiten Sie eine *Probandeneinwilligungserklärung* für die Probanden vor.	○	●	○	◕	◑	●	●	●
8	Erstellen Sie einen *Fragebogen*, um personenbezogene Daten (z. B. Alter, Gewicht) von den Probanden zu erfassen.	◔	●	○	◕	◕	●	◕	●
9	Holen Sie ein positives *Ethikvotum* für die geplante Studie/Aufnahme ein.	○	○	○	◕	○	●	○	●
Vorbereitung der Datenaufnahme									
10_a	Akquirieren Sie *genügend Probanden*, um die demografische Variabilität in dem Anwendungsbereich widerzuspiegeln.	◔	◔	○	◑	●	◕	◔	●
10_b	Akquirieren Sie *Ersatzprobanden*, die nicht zum Studienteam gehören.	○	○	○	○	○	◕	○	●
10_c	Senden Sie allen Probanden einige Tage vor der Aufnahme die *Probandeninformation*, den *Fragebogen* und die *Probandeneinwilligungserklärung* zu.	○	●	○	◑	○	●	●	●
11_a	Stellen Sie sicher, dass die *Altersverteilung* der *Zielgruppe* entspricht.	◑	◕	○	◔	◕	◔	○	◕

Tabellenfortsetzung

Checkliste für jeden Schritt des Frameworks		Umfrageergebnisse							
		HDM05	HDM12	HuGaDB	UMAFall	LARa	OpenPack	CAARL	DaRA
11_b	Stellen Sie sicher, dass die *Geschlechterverteilung* der *Zielgruppe* entspricht.	○	◕	◑	●	◕	◔	◑	◕
11_c	Stellen Sie sicher, dass die *Händigkeit* innerhalb der *Zielgruppe* ausgewogen ist.	○	◑	○	◑	●	◑	○	◕
11_d	Stellen Sie sicher, dass die *beruflichen Qualifikationen* die *Zielgruppe* widerspiegeln.	○	◑	○	◔	○	●	○	◔
11_e	Stellen Sie sicher, dass die *aktivitätsbezogene Erfahrung* die *Zielgruppe* widerspiegelt.	◑	◕	◔	◔	◔	●	○	◑
11_f	Stellen Sie sicher, dass *Körpergröße* und *Körpermasse* repräsentativ für die *Zielgruppe* sind.	◑	◕	◕	◑	●	◕	◔	●
12	Erstellen Sie *Aufnahmeprotokolle* zur Dokumentation (z. B. Zuordnung von Probanden-IDs zu Sensor-IDs, Beginn der Sessions, Störungen, Platzierung der Sensoren).	●	◕	○	◕	●	●	●	●
13	Beschaffen und testen Sie die *Sensorsysteme*.	◕	●	●	◕	●	◕	●	●
14	Richten Sie die *Aufnahmeumgebung* ein.	●	●	●	◕	●	●	●	●
15	Führen Sie vor der Hauptaufnahme *Testaufnahmen* durch, um die Aufnahmepipeline zu validieren.	●	◕	●	◕	◑	◑	◕	●
	Durchführung der Datenaufnahme								
16	Stellen Sie sicher, dass alle Probanden vor der Aufnahme die *Probandeneinwilligungserklärung* unterzeichnet haben.	○	●	○	◑	○	●	●	●
17_a	Führen Sie das *Protokoll* vor, während und nach der Datenaufnahme.	●	◕	○	◑	●	●	●	●
17_b	Stellen Sie sicher, dass alle Probanden den *Fragebogen* ausgefüllt haben.	●	●	●	◕	●	●	●	●
18	Führen Sie eine *Kalibrierung* durch, um Messfehler zu minimieren.	●	●	●	◑	●	◑	●	●
19	Stellen Sie die *Synchronisation* aller Sensoren im Falle eines Multisensor Datensatzes sicher.	○	◑	●	◕	●	◑	●	●
20	Führen Sie mit jedem Probanden *Probeläufe* durch.	●	◕	●	◑	◕	◕	●	●
21_a	*Minimieren Sie Eingriffe* durch das Aufnahmeteam, um ein natürliches Verhalten der Probanden zu ermöglichen.	◔	◕	●	◕	◕	◑	◕	●
21_b	*Überprüfen* Sie regelmäßig, ob alle *Sensoren* während und zwischen den Aufnahmesession korrekt aufzeichnen.	●	●	●	◕	◕	◑	◕	●
	Vorbereitung der Datenverarbeitung								
22	Definieren Sie die *Klassenlabels* klar und eindeutig.	●	◑	●	●	●	●	●	●
23	Definieren Sie *Abhängigkeiten* zwischen Klassenlabels (z. B. schließen sich „Stehen" und „Gangzyklus" als gleichzeitige Labels aus).	◑	◑	●	●	◕	◕	◕	●
24	Akquirieren Sie *Annotatoren* und *Revisoren*.	◔	○	◑	○	●	●	●	●
25	Wählen Sie ein *Annotationstool* aus und testen Sie es.	◕	◑	●	◕	●	●	●	●
26_a	Erstellen Sie klare *Annotationsrichtlinien*.	◑	◑	●	◑	●	◑	●	●
26_b	Arbeiten Sie *Annotatoren* und *Revisoren* ein.	◔	◔	◑	○	●	●	●	●
	Durchführung der Datenverarbeitung								
27	*Exportieren*, formatieren und kontrollieren Sie die *Sensordaten*.	●	●	●	●	●	◕	●	●
28_a	*Synchronisieren* Sie alle *Sensordaten*.	●	◑	●	●	●	◕	●	●
28_b	*Benennen Sie die Sensordaten* anhand des Probanden, der Aufnahmesession, des Szenarios und/oder der Aufnahmenummer.	●	●	●	●	●	◕	●	●
29_a	Führen Sie *Testannotationen* mit Annotatoren und Revisoren durch, um die Qualität der Labels zu ermitteln.	◕	●	◑	◑	●	●	●	●
29_b	Führen Sie während der Annotation regelmäßig *Stichproben (Qualitätskontrolle) der Arbeit jedes Annotators* durch.	◕	◔	●	◑	○	○	○	◔
29_c	Stellen Sie sicher, dass die Sensordaten *vollständig gelabelt* sind.	●	◕	●	●	◕	◑	●	●

Tabellenfortsetzung

Checkliste für jeden Schritt des Frameworks		Umfrageergebnisse							
		HDM05	HDM12	HuGaDB	UMAFall	LARa	OpenPack	CAARL	DaRA
30	Führen Sie eine *Revision aller Annotationen* mit wenige Experten durch.	◕	◔	◑	○	◑	○	◑	◕
31_a	Korrigieren oder dokumentieren Sie *Fehler* und *Abweichungen* in den Daten (asynchrone Daten, fehlende Daten).	●	◔	○	●	◑	◕	◑	◕
31_b	Korrigieren Sie *Labelungleichgewicht* im Datensatz.	◑	○	○	◑	◑	○	○	○
31_c	Führen Sie eine *Qualitätskontrolle* der *Sensordaten* durch.	●	○	○	◑	●	◑	●	●
32	Stellen Sie sicher, dass die *Labelqualität* ausreichend ist.	●	○	○	◑	◕	◕	◕	●
	Veröffentlichung des Datensatzes								
33_a	Veröffentlichen Sie die **Daten** in einem *Repository* mit einer global eindeutigen und dauerhaften *Kennung* (z. B. DOI).	◕	◑	●	●	●	●	●	●
33_b	Stellen Sie sicher, dass die *Daten offen* und *kostenlos zugänglich* sind.	●	●	●	●	●	●	●	●
33_c	Stellen Sie *Sensordaten* und *Labels* in einem formalen, zugänglichen und *weit verbreiteten Format* (z. B. CSV) bereit.	●	◕	●	●	◕	●	◕	●
33_d	Stellen Sie sicher, dass alle *Dateibezeichnungen*, *Labels* und *Metainformationen auf Englisch* sind.	●	●	●	●	●	●	●	●
33_e	Geben Sie die Daten mit einer *Nutzungslizenz* an.	◔	◑	●	◕	●	●	●	●
33_f	Verknüpfen Sie die Daten mit ihren *Herkunftsinformationen* (Land, Stadt, Organisation).	◑	○	●	●	●	○	●	●
33_g	Fügen Sie *Referenzen* auf die Datenbeschreibung, das Framework, in dem der Datensatz erstellt wurde, und verwandte Datensätze hinzu.	◑	◑	●	●	●	◕	●	●
33_h	*Registrieren* oder *indizieren Sie die Daten*, damit sie leicht auffindbar sind.	◑	○	○	●	●	○	●	●
34_a	Stellen Sie sicher, dass die *Sensordaten* nach Möglichkeit *synchron* sind.	●	◑	●	◕	○	◕	○	●
34_b	Stellen Sie sicher, dass alle *Sensordaten gelabelt* sind.	●	◑	●	●	●	◑	●	●
34_c	Fügen Sie ein *Skriptbeispiel* hinzu, das zeigt, *wie die Daten verwendet werden könnten*.	●	◕	●	◑	●	●	●	●
34_d	Stellen Sie sicher, dass das *Annotationstool* in einem *Repository* verfügbar ist.	◑	◔	○	◑	●	○	●	●
35	Veröffentlichen Sie ein *Vorverarbeitungsskript*.	◑	◔	○	○	○	●	○	●
36_a	Veröffentlichen Sie eine **Datensatzbeschreibung** in *englischer Sprache*.	●	●	●	●	●	●	●	●
36_b	Veröffentlichen Sie eine *Datensatzbeschreibung* in einem *Repository*.	●	●	●	●	●	●	●	●
36_c	Veröffentlichen Sie eine *Datensatzbeschreibung* in einer *frei zugänglichen Publikation* mit einer dauerhaften *Kennung* (z. B. DOI).	◕	○	●	●	●	●	●	●
36_d	Stellen Sie sicher, dass die *Datensatzbeschreibung offen* und *kostenlos zugänglich* ist.	●	●	●	●	●	●	●	●
36_e	Beschreiben Sie die *Sensorkonfiguration*.	●	●	●	●	◑	●	◕	●
36_f	Beschreiben Sie die *Datenaufnahmepipeline*.	◑	◕	●	●	●	●	●	●
36_g	Beschreiben Sie die *Probandencharakteristiken* (z. B. Alter, Qualifikationen, Körpergröße).	◑	◑	●	●	●	●	●	●
36_h	Beschreiben Sie die *Labels* im Detail.	◕	◕	●	●	●	◑	●	●
36_i	Dokumentieren Sie den *Annotations-* und *Revisionsprozess*.	◑	◕	●	◑	◔	◑	◔	●
36_j	Dokumentieren Sie die *Ergebnisse* der *Annotationen* und *Revisionen*.	◑	◕	●	◑	●	◑	●	●
36_k	Beschreiben Sie die *Qualität* der *revidierten Labels*.	◕	◔	●	●	○	○	○	●
36_l	Beschreiben Sie die *Qualität* der *Sensordaten*.	◕	◔	●	●	○	●	○	●
36_m	Fügen Sie die *Datenkennung in die Beschreibung ein*.	●	○	●	●	●	○	●	●

6.1.2 Anwendbarkeit der Checkliste in verwandten Forschungsbereichen

Die Checkliste ist für Anwendungsfälle mit synthetisch generierten Daten, etwa durch Simulation, Motion-Capture-Resynthese oder KI-basierte Verfahren, nur eingeschränkt geeignet. In diesen Szenarien entfallen zentrale Schritte der Datenaufnahme, während Aspekte wie Modellvalidierung und der Abgleich mit realen Aufzeichnungsdaten an Bedeutung gewinnen. Diese Aspekte werden jedoch nicht durch die Checkliste abgedeckt.

6.1.3 Anwendbarkeit der Checkliste in Unternehmen

Im Folgenden werden die bei der MotionMiners GmbH angewandten Vorgehensweisen bei der Erstellung von Datensätzen für industrielle HAR-Anwendungen dargestellt. Aufgrund der spezifischen organisatorischen und technischen Rahmenbedingungen sind die beschriebenen Prozesse als unternehmensspezifisch zu betrachten.

Planung der Datensatzerstellung: Zweck und Umfang des Datensatzes werden pragmatisch aus dem jeweiligen industriellen Anwendungsfall abgeleitet. So werden in Unternehmen HAR-Modelle gezielt an kundenspezifische Anforderungen in Lagerumgebungen angepasst.

Vorbereitung und Durchführung der Datenaufnahme: Die Datenaufnahme erfolgt in kurzen, mit dem Kunden abgestimmten Aufnahmesessions mit ein bis zwei Mitarbeitenden. Dabei werden ethische Aspekte, wie die Sichtbarkeit von Gesichtern oder die Anwesenheit unbeteiligter Personen, berücksichtigt und Kalibrierungsaufnahmen mit IMU- und BLE-Daten durchgeführt.

Vorbereitung und Durchführung der Datenverarbeitung: Eine hohe Datenqualität wird durch hardwareseitige Maßnahmen wie Sensorsynchronisation und redundante Sensorsätze sichergestellt. Die Videoannotation erfolgt intern durch Experten und dient primär der Modellbewertung und -anpassung, wobei Revisionen mit systematischen Konsistenzprüfungen aus Zeit- und Kostengründen entfallen.

Veröffentlichung des Datensatzes: Aufgrund vertraglicher und datenschutzrechtlicher Vorgaben werden die Datensätze nicht veröffentlicht und verbleiben vollständig im Eigentum von Unternehmen, was die freie Verfügbarkeit industrieller Datensätze und damit die Weiterentwicklung von Methoden erheblich einschränkt.

6.2 Empirische Evaluation des DaRA-Datensatzes

Die Gesamtqualität des DaRA-Datensatzes ergibt sich aus der Konsistenz der Labels nach Annotation und Revision, der Qualität der erfassten Sensordaten sowie deren Eignung für die Anwendung in der HAR. Neben der Bewertung

der Labelqualität wird das Vorgehen der kategorieweisen, sequenziellen Annotation und Revision zusätzlich durch einen Vergleich der Analysiergeschwindigkeiten zwischen MTM-Methoden und HAR-Datensätzen evaluiert.

6.2.1 Labelqualität

Die Labelqualität wird anhand der Testannotationen (siehe Schritt 26) mit Cohens κ und Lights κ quantifiziert. Die Gesamtübereinstimmung wird als makro-κ zusammengefasst beschrieben, das als ungewichteter Mittelwert der labelweisen κ-Werte definiert ist. Da selten auftretende Labels in den Testannotationen zu instabilen κ-Schätzungen führen, wurde ein gefiltertes makro-κ verwendet. Dieses berücksichtigt ausschließlich Labels mit ausreichender Unterstützung, definiert als ein Anteil von mindestens 0,5 % der Frames. Die Ergebnisse der κ-Berechnungen sind in Tabelle 6.2 getrennt nach Annotation, Revision und Klassenkategorien zusammengefasst.

Tabelle 6.2 Labelqualität (κ-Werte) des DaRA-Datensatzes bei Annotationen und Revisionen, aufgeschlüsselt nach Klassenkategorien

Klassenkategorie				Cohens κ / Lights κ [%]	
ID	Name	M	K	Annotation	Revision
KK01	Hauptaktitvität	X		75,77	80,59
KK02	Teilaktivität - Beine	X		60,99	78,27
KK03	Teilaktivität - Torso	X		40,83	81,61
KK04	Teilaktivität - Linke Hand	X		71,32	78,35
KK05	Teilaktivität - Rechte Hand	X			
KK06	Auftrag		X	95,44	99,88
KK07	Hardware für die informationstechnische Führung		X	95,20	99,86
KK08	Grobprozess		X	94,53	99,85
KK09	Teilprozess		X	89,63	98,63
KK10	Feinprozess		X	73,25	90,95
KK11	Lokalisierung - Mensch		X	88,54	98,04
KK12	Lokalisierung - Kommissionierwagen		X	92,47	98,16

Anmerkung: Die Klassen KK04 und KK05 sind semantisch gleich definiert. Entsprechend wurde die Testannotation und -revision ausschließlich für *Teilaktivität - Linke Hand* durchgeführt; die resultierenden Werte sind auf *Teilaktivität - Rechte Hand* übertragbar. M = menschliche Bewegung, K = Kontext

Nach der Revision liegt der durchschnittliche Makro-Light-κ-Wert zwischen 78,27 % (KK02, *Teilaktivität - Beine*) und 99,88 % (KK06, *Auftrag*). Gemäß gängigen Benchmarks entspricht dies einer *sehr guten* bis *fast perfekten* Übereinstimmung (siehe grüne Markierungen in Abbildung 6.1). Die Ergebnisse zeigen Unterschiede in der Übereinstimmungstärke zwischen den Kategorien der menschlichen Bewegungen (KK01–KK05; 78,27–81,61 %) und Kontextkategorien (KK06–KK12; 90,95–99,88 %). Ein ähnliches Muster ist ebenso in den Testannotationen vor der Revision erkennbar (siehe gelbe Markierun-

gen). Insgesamt deuten diese Ergebnisse darauf hin, dass Kontextsegmente einfacher und konsistenter zu labeln sind als menschliche Bewegungen.

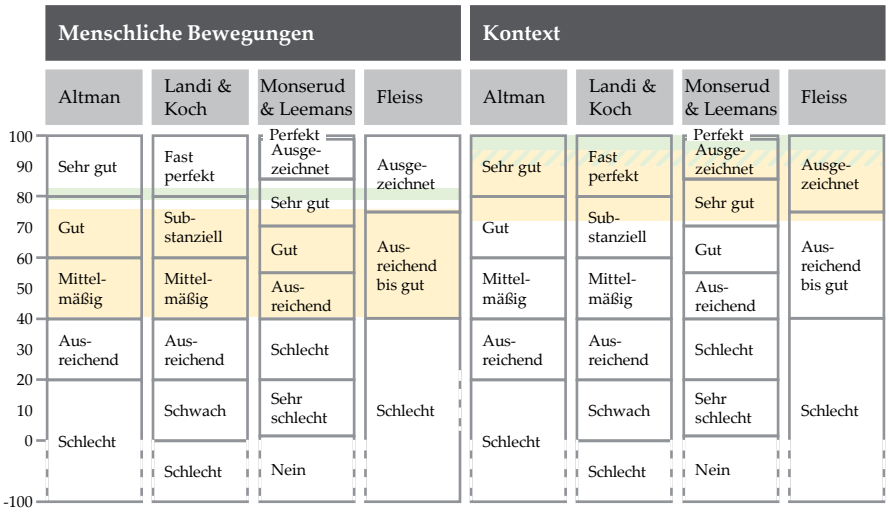


Abb. 6.1 Interpretation der Labelqualität auf Grundlage der κ-Koeffizienten nach der Annotation (gelb) und nach der Revision (grün), differenziert nach Labeln der menschlichen Bewegung und des Kontexts [Alt90; Cza94; Fle73; Foo20; LK77; ML92] (siehe Abbildung 4.9)

Wesentliche Verbesserungen von der Annotation zur Revision, beispielsweise in KK02 (*Teilaktivität - Beine*; von 60,99 % auf 78,27 %), in KK05 (*Teilaktivität - Torso*; von 40,83 % auf 81,61 %) und KK10 (*Feinprozess*; von 73,25 % auf 90,95 %) sind teilweise auf die Verwendung der Labels *Andere* und *Unbekannt* während der Annotation zurückzuführen, wenn eine eindeutige Zuordnung nicht möglich schien. Während der Revision wurden solche Segmente überwiegend spezifischeren Labels zugeordnet, wodurch die Übereinstimmung teilweise erheblich verbessert wurde.

6.2.2 Analysiergeschwindigkeit

Wie in Schritt 2 des Frameworks dargestellt, übersteigt der Aufwand für die Analyse menschlicher Bewegungen den Aufwand für die reine Datenaufnahme deutlich. Die Analysiergeschwindigkeit stellt damit den zentralen Aufwands- und Kostentreiber bei der Erstellung von HAR-Datensätzen dar.

Die Tabelle 6.3 vergleicht klassische MTM-Bausteinsysteme (MTM-1, MTM-SD, UAS, MEK, siehe Abschnitt 2.2.5) mit HAR-Datensätzen (LARa, CAARL, DaRA) hinsichtlich relevanter Aufwandsfaktoren. Die Analysiergeschwindigkeit wird dabei im Wesentlichen durch zwei Faktoren bestimmt: die mittlere Zeitbaustein- bzw. **Segmentgröße** sowie die Anzahl der auswählbaren Grundbewegungen bzw. **Labelanzahl**.

Tabelle 6.3 Vergleich der Geschwindigkeit von MTM-Analysierverfahren [MTM26] mit der manuellen Annotations- und Revisionsgeschwindigkeit für die Erstellung der HAR-Datensätze LARa [Nie+20c], CAARL [Nie+21a] und DaRA [Nie+26b] (angelehnt an [Deu+16, S. 199]). Die Analysiergeschwindigkeit ist als Verhältnis von Datenaufnahme zu Analysierzeit angegeben.

	MTM-Bausteinsysteme				**HAR**		
	MTM-1	MTM-SD	UAS	MEK	LARa	CAARL	DaRA
$\bar{x}$ Zeitbaustein-/Segmentgröße [Sek.]	0,288	0,54	1,8	3,6	1,86	1,78	0,94
Anzahl Bewegungsgruppen/Kategorien	10	6	7	7	5	5	12
Anzahl Grundbewegungen/Labels	19	11	10	10	27	27	207
Analysiergeschwindigkeit	1 : 200	1 : 80-200	1 : 10-20	1 : 10	1 : 48,84	1 : 19,17	1 : 60,57

Ein wesentlicher Einflussfaktor ist die **Segmentgröße**. Grundsätzlich zeigt sich, dass eine feinere Segmentierung zu einem erhöhten Analyseaufwand führt. Dies wird insbesondere durch MTM-1 deutlich, dass mit der kleinsten mittleren Zeitbausteingröße von 0,288 Sekunden das höchste Analyseverhältnis von 1:200 aufweist (siehe Abschnitt 2.2.5). Gleichzeitig steigt mit zunehmender Granularität die Detailtiefe der erhobenen Zeitdaten.

Anders als LARa und CAARL, verfolgt DaRA eine kategorieweise, sequenzielle Methode, bei der jede Aufnahme entsprechend der Anzahl der Klassenkategorien mehrfach annotiert und revidiert wird. Trotz dieser deutlich erhöhten Annotationstiefe – zwölf Annotations- und Revisionsebenen pro Aufnahme – sowie einer im Vergleich zu LARa rund halb so großen mittleren Segmentgröße erreicht DaRA eine Analysiergeschwindigkeit von 1:60,57. Damit liegt DaRA nur moderat unter der Geschwindigkeit von LARa, obwohl aus struktureller Sicht ein deutlich höherer Analyseaufwand zu erwarten wäre.

Der Einfluss der **Labelanzahl** auf die Analysiergeschwindigkeit ist demgegenüber geringer ausgeprägt. Dies zeigen MTM-SD, UAS und MEK, die trotz vergleichbarer Anzahl an Grundbewegungen deutlich unterschiedliche Analysiergeschwindigkeiten aufweisen. Bei HAR-Datensätzen wird der Effekt jedoch sichtbar: LARa weist bei ähnlicher Segmentgröße wie UAS eine deutlich geringere Analysiergeschwindigkeit auf, was auf die höhere Labelanzahl zurückzuführen ist.

Bei der Erstellung des CAARL-Datensatzes wurden die Bewegungen automatisch klassifiziert und anschließend manuell revidiert. Dieses semiautomatische Verfahren [Avs+21a] reduziert den Analysierzeitaufwand gegenüber dem LARa-Datensatz, bei gleichen Klassenlabels, deutlich von 48,84 auf

19,17 Minuten je Aufnahmeminute (siehe Abschnitt 4.1.1). DaRA nimmt mit 207 Labels eine Sonderstellung ein. Hervorzuheben ist, dass sich diese hohe semantische Detailtiefe trotz einer manuellen Annotation im Vergleich zum LARa-Datensatzes nicht in einer proportional niedrigeren Analysiergeschwindigkeit widerspiegelt.

Insgesamt zeigt sich, dass die kategorieweise, sequenzielle Annotation und Revision bei DaRA trotz deutlich erhöhter struktureller Komplexität eine vergleichsweise hohe Analysiergeschwindigkeit ermöglicht. In Kombination mit der hohen Labelqualität (siehe Abschnitt 6.2.1) unterstreicht dies die Eignung des DaRA-Ansatzes für detaillierte und zugleich effiziente HAR-Datensatzerstellungen und stellt einen klaren Vorteil gegenüber etablierten Annotationsverfahren dar.

6.2.3 Sensordatenqualität

Kameras: Die Sensorsynchronisation der stationären Kameras erfolgte appbasiert über eine Kombination aus Bluetooth (zur Geräteerkennung) und WLAN (zur Datenübertragung). Die Metadaten der mobilen Kameras wurden appbasiert mithilfe von QR-Codes synchronisiert.

Im Anschluss wurden die Videostreams der stationären und mobilen Kameras manuell anhand visueller und auditiver Merkmale synchronisiert. Als visuelle Referenzen dienten schnelle Bewegungen der Probanden (insbesondere Gehbewegungen) in Kombination mit Bodenmarkierungen sowie eine Atomuhr als globaler Zeitstempel. Bei längeren Aufnahmen, größeren Abständen zwischen den via Bluetooth verbundenen stationären Kameras sowie beim Wechsel der Akkus der mobilen Kameras traten vereinzelt kurze zeitliche Versätze auf, die nachträglich manuell korrigiert wurden. Verbleibende Abweichungen sind minimal und liegen im Bereich von null bis drei Frames (bis zu 0,1 Sekunden). Ein illustratives Beispiel ist in Abbildung 5.6 dargestellt: Während der Fuß im Kamerabild (b) noch auf der Linie steht, befindet er sich im Kamerabild (h) leicht dahinter, was einem Versatz von einem Frame (bis zu 0,03 Sekunden) entspricht.

IMUs und Beacons: Jedes tragbare Set der MotionMiners GmbH umfasst drei Geräte (rechter Arm, linker Arm, Hüfte) und zeichnet die Daten eines dreidimensionalen Beschleunigungsmessers, eines dreidimensionalen Gyroskops sowie RSSI-Messwerte von allen Beacons auf. Die RSSI-Signale werden für die Indoorlokalisierung mittels einer Fingerprinting Methode verwendet, bei der ein Bereich durch statistische Merkmale aus den RSSI-Signalen der drei Geräte für einen bestimmten Zeitraum dargestellt wird.

Die Geräte gewährleisten eine verlustfreie Aufzeichnung der IMU-Daten, da die Daten zunächst lokal gespeichert und erst nach Abschluss der Aufnahme übertragen werden. Dennoch kommt es im Falle von Geräteschäden zum Verlust vollständiger Aufzeichnungen, wie bei Proband P10, für den

das zweite Geräteset nicht aufgezeichnet wurde. Die Daten des ersten Sets lagen jedoch fehlerfrei vor.

6.2.4 Qualität von Label-Sensor-Kombinationen mittels HAR

Nach der getrennten Evaluation von Labels und Sensoren wird nun deren Kombination untersucht. Hierfür wird in Anlehnung an [Moy+18; Nie+20a] ein TCNN als HAR-Baseline mit IMU-Daten trainiert. Die beim Training eingesetzten Hyperparameter sind dem Beitrag [Nie+26a] zu entnehmen, der zugleich das Versuchsprotokoll der nachfolgenden Experimentergebnisse dokumentiert.

Entsprechend den in [BBS14; OR16] beschriebenen Trainingsverfahren wurden die IMU-Daten in Trainings-, Validierungs- und Testdatensätze unterteilt. Der Trainingsdatensatz umfasst Aufnahmen der Probanden [P02, P03, P04, P06, P07, P08, P10, P11, P12, P13, P15, P16], während die Validierungs- und Testdatensätze die Probanden [P01, P05, P18] bzw. [P09, P14, P17] enthalten. Aufnahmen mit den Klassenlabels *Synchronisation* (KL001), *Andere Hauptaktivität* (KL014) und *Hauptaktivität unbekannt* (KL015) wurden vom Training ausgeschlossen.

Tabelle 6.4 zeigt Recall und Precision Werte der Aktivitätsklassenvorhersage bei Verwendung einer Softmax. Die Aktivitätsklassen *Quittierung per Stift*, *Gehen* und *Stehen* weisen die höchsten Recall Werte auf, während sowohl Recall als auch Precision für die Klasse *Quittierung per Touchscreen* bei Null sind.

Tabelle 6.4 Klassifikationsleistung der Aktivitätserkennung je Aktivitätsklasse (Softmax)

Aktivitätsklasse		Softmax	
ID	Name	Recall [%]	Precision [%]
KL002	Quittierung per Stift	91,18	3,05
KL003	Quittierung per Touchscreen	0,00	0,00
KL004	Quittierung per Taste	57,50	4,01
KL005	Scannen	18,97	7,42
KL006	Kommissionierwagen ziehen	78,16	66,89
KL007	Kommissionierwagen schieben	74,21	90,38
KL008	Handhabung überkopf	54,17	61,39
KL009	Handhabung neutral	71,99	84,23
KL010	Handhabung gebeugt	66,45	54,37
KL011	Gehen	80,00	75,36
KL012	Stehen	81,88	67,83

Tabelle 6.5 zeigt die Konfusionsmatrix aus den Aktivitätsklassenvorhersagen unter Verwendung des TCNN mit der Softmax-Layer. Die drei *Quittie-*

*rungs*aktivitäten weisen eine geringe Klassifikationsgenauigkeit bei gleichzeitig hohen Falsch-Positiv Werten auf. Diese Aktivitäten sind schwer zu erkennen, da sie nur in geringer Stichprobenzahl vorliegen und teilweise eine vergleichsweise kurze Ausführungsdauer aufweisen. Die Aktivitätsklasse *Scannen* wird tendenziell als *Handhabung neutral* vorhergesagt, da beide Aktivitäten ein ähnliches Bewegungsmuster zeigen.

Tabelle 6.5 Klassifikationsleistung der Aktivitätserkennung: Konfusionsmatrix der Aktivitätsklassen (Softmax)

		Vorhergesagte Klasse										
		Quittierung per Stift	**Quittierung per Touchscreen**	**Quittierung per Taste**	**Scannen**	**Kommissionierwagen ziehen**	**Kommissionierwagen schieben**	**Handhabung überkopf**	**Handhabung neutral**	**Handhabung gebeugt**	**Gehen**	**Stehen**
Tatsächliche Klasse	**Quittierung per Stift**	**124**	0	0	32	7	43	1948	1623	83	121	87
	Quittierung per Touchscreen	0	**0**	5	0	1	12	45	367	42	106	107
	Quittierung per Taste	0	0	**46**	3	0	3	161	609	167	155	2
	Scannen	0	63	1	**291**	6	9	340	1924	534	156	600
	Kommissionierwagen ziehen	0	0	0	0	**2347**	775	6	374	3	3	1
	Kommissionierwagen schieben	0	0	0	0	249	**6276**	0	411	0	3	5
	Handhabung überkopf	11	1	12	191	19	58	**7899**	4513	14	119	29
	Handhabung neutral	1	26	4	502	319	883	3251	**64222**	2079	3157	1805
	Handhabung gebeugt	0	1	1	51	0	2	63	4858	**6711**	467	190
	Gehen	0	0	6	2	15	303	155	5398	62	**20004**	598
	Stehen	0	0	5	462	40	93	714	4906	404	714	**15473**

Tabelle 6.6 zeigt die Gesamtleistung der Methode unter Verwendung eines Softmax- bzw. Sigmoid-Layers, basierend auf Teilaktivitäten als Attributen. Die Ergebnisse stehen im Einklang mit den Arbeiten von [Moy+18; Rei+18a; Rei21], in denen gezeigt wird, dass Attributvorhersagen (Sigmoid) für HAR zu einer verbesserten Klassifizierungsleistung führen.

Tabelle 6.6 Gesamte Klassifikationsleistung der Aktivitätserkennung

Metrik	**Softmax**	**Sigmoid**
Accuracy [%]	72,12	74,62
gewichteter F1 [%]	70,40	73,70

6.3 Empirische Evaluation der Prozesserkennung

Zur Evaluation der in Abschnitt 4.2 entwickelten Datenverarbeitungskette wurde der DaRA-Datensatz (Abschnitt 5.1) unter Verwendung der in Abschnitt 5.2 als relevant identifizierten Inputdaten eingesetzt. Die beim Training verwendeten Hyperparameter sind dem Beitrag [Rue+26] zu entnehmen.

Versuchsdurchführung

Tabelle 6.7 zeigt die Versuchsdurchführung zur Bewertung der Datenverarbeitungskette. Für die Erkennung von Fein- und Teilprozessen wurden Embeddings eines TCNN-Merkmalsextraktors verwendet. Zusätzlich dienten Ground-Truth Annotationen von Hauptaktivitäten, von Lokalisierung der Probanden und von Prozessebenen als kategoriale Eingabesequenzen, ähnlich wie in [SF09]. Insgesamt wurden acht Eingabe→Ausgabe-Kombinationen unter einer subjektweisen Aufteilung (14 Trainings-, ein Validierungs- und drei Testprobanden) untersucht. Diese Kombinationen ermöglichen die Bestimmung von Obergrenzen für die Prozesserkennung.

Tabelle 6.7 Übersicht der Experimente zur Prozesserkennung unter Berücksichtigung verschiedener Eingabemerkmalskonfigurationen

(i)	**Embeddings**	→ **Feinprozess**
(ii)	**Hauptaktivität**	→ **Feinprozess**
(iii)	**Hauptaktivität** + **Lokalisierung (Mensch)**	→ **Feinprozess**
(iv)	**Embeddings**	→ **Teilprozess**
(v)	**Hauptaktivität**	→ **Teilprozess**
(vi)	**Hauptaktivität** + **Lokalisierung (Mensch)**	→ **Teilprozess**
(vii)	**Feinprozess**	→ **Teilprozess**
(viii)	**Teilprozess**	→ **Grobprozess**

Ergebnisse nach Klassenkategorien

Die Ergebnisse sind in Tabelle 6.8 als gewichtetes F1-Maß dargestellt. Die Tabelle vergleicht die Leistung der Sequenzmodelle – LSTM, Transformer und HMM – für verschiedene Eingabemerkmale und Prozessebenen. Aus den Ergebnissen lassen sich zwei wesentliche Erkenntnisse ableiten.

Erstens steigt die Erkennungsleistung mit zunehmendem **Aggregationsgrad** der Prozesse. Während Feinprozesse maximal 58,67 % erreichen, steigt die Leistung bei Teilprozessen je nach Eingabekonfiguration auf 79,56 % bis 98,40 %. Feinprozesse weisen offenbar ähnliche Bewegungsmuster und räumliche Abhängigkeiten auf, was ihre Unterscheidung erschwert. Teilprozesse sind hingegen deutlicher voneinander abgrenzbar. Zusätzliche Versuche mit angepassten Hyperparametern (nicht in Tabelle 6.8 dargestellt) erhöhten die Leistung der Feinprozesserkennung auf 65,56 %, liegen jedoch weiterhin unter der der Teilprozesse.

Tabelle 6.8 Gesamte Klassifikationsleistung der Prozesserkennung: gewichtetes F1-Maß für drei Sequenzmodelle in Abhängigkeit von den verwendeten Eingabemerkmalskonfigurationen und den Prozessebenen als Output

Input → Output	Embeddings → Feinp.	Akt. → Feinp.	Akt.+Lok. → Feinp.	Embeddings → Teilp.	Akt. → Teilp.	Akt.+Lok. → Teilp.	Feinp. → Teilp.	Teilp. → Grobp.
LSTM	3,34	44,34	57,06	4,85	58,06	74,12	**98,40**	**95,18**
Transformer	47,30	**45,77**	**58,67**	**42,31**	**77,67**	**78,65**	97,55	91,55
HMM	**48,70**	19,24	NaN*	39,78	42,34	NaN*	89,48	93,43

Anmerkung: Akt. = Hauptaktivität, Lok. = Lokalisierung - Mensch, p. = Prozess, *Das Gaussian Mixture Model, das die Verkettung der Embeddings und der Lokalisierung nutzt, weist eine Singularitätsvarianz auf.

Zweitens verbessert sich die Modellleistung mit dem **Informationsgehalt** der Eingaben. Die Erweiterung von Hauptaktivitäten um Lokalisierungsinformationen erhöht das F1-Maß aller Modelle um 2 % bis 16 %. Obwohl Embeddings relevante Informationen enthalten, liefern sie weniger konsistente Ergebnisse. So erreicht das LSTM bei der Verwendung von Embeddings für Fein- und Teilprozesse nur 3,34 % bzw. 4,85 %. Das HMM erzielt mit Embeddings hingegen bessere Ergebnisse als mit Hauptaktivitäten allein. Der Transformer verbessert die Feinprozesserkennung mit Embeddings, schneidet jedoch bei Teilprozessen schlechter ab als mit aktivitätsbasierten Merkmalen. Insgesamt liefert die Kombination aus Hauptaktivitäten und Lokalisierung die besten Ergebnisse, was darauf hindeutet, dass semantische Prozessmerkmale informativer sind als rein bewegungsbasierte Merkmale.

Zwischen den Modellarchitekturen zeigen sich ebenfalls Unterschiede. Das LSTM ist stark auf explizite semantische Struktur in den Eingaben angewiesen. Der Transformer zeigt die robusteste Leistung über verschiedene Eingabekonfigurationen hinweg, auch wenn er nicht immer die höchsten Werte erzielt.

Werden ausschließlich Prozessebenen als Eingaben verwendet, lassen sich aggregierte Prozesse mit hoher Genauigkeit aus granulareren Ebenen ableiten. Teilprozesse lassen sich aus Feinprozessen (bis zu 98,40 %) und Grobprozesse aus Teilprozessen (bis zu 95,18 %) erkennen. Dies bestätigt das Prinzip der hierarchischen Modellierung in Abbildung 5.15.

Ergebnisse nach Klassenlabels

Die klassenlabelweise Betrachtung der F1-Maße zeigt deutliche Unterschiede in der Erkennungsleistung auf Klassenebene zwischen Fein- und Teilprozessen. Während die Teilprozesse insgesamt relativ homogen erkannt werden, weist die Feinprozesserkennung eine ausgeprägte Streuung über die einzelnen Klassenlabels auf.

Beim Transformer-Modell erreichen 16 Feinprozessklassen ein F1-Maß von über 70 %, während gleichzeitig sieben Klassen überhaupt nicht erkannt werden (F1 = 0 %). Dies deutet darauf hin, dass das Modell für einen Teil

der Klassen keine generalisierbaren Muster gelernt hat. Ein Vergleich der jeweils besten Feinprozesserkennungsleistung der betrachteten Modelle ist in Abbildung 6.2 dargestellt. Dabei zeigt sich, dass die Unterschiede zwischen den Klassen unabhängig vom Modell bestehen bleiben und somit primär durch die Eigenschaften der einzelnen Klassenlabels bestimmt werden.

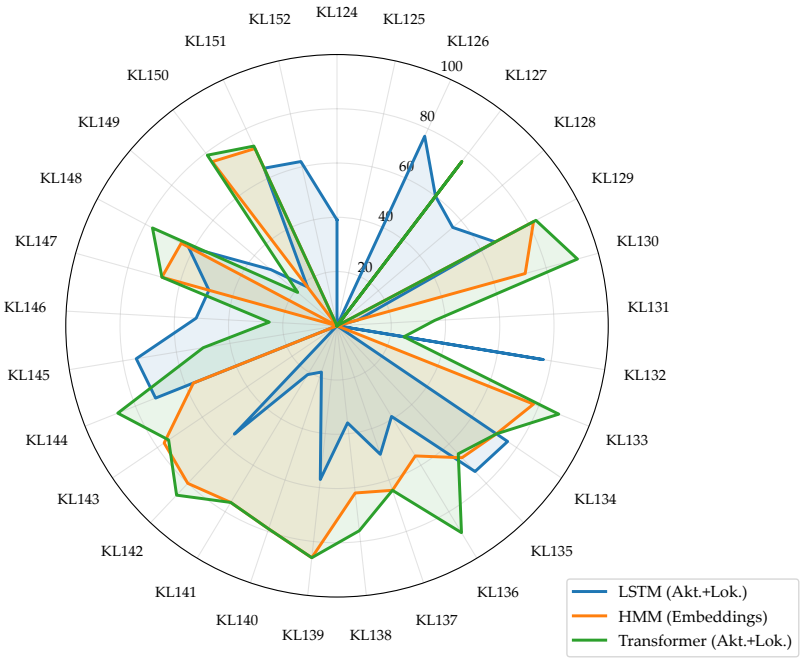


Abb. 6.2 Vergleich der Feinprozesserkennungsleistung von LSTM, Transformer und HMM unter ihren jeweils leistungsstärksten Eingabemerkmalskonfigurationen (*Hauptaktivität + Lokalisierung*, *Embeddings*) auf Basis des klassenweisen F1-Maßes

Im Gegensatz dazu werden die Teilprozesse deutlich konsistenter erkannt (siehe Abbildung 6.3). Für das Transformer-Modell mit Hauptaktivität und Lokalisierung als Eingabemerkmale liegen die F1-Maße in einem vergleichsweise engen Bereich zwischen 65 % und 98 %. Dies deutet darauf hin, dass die Teilprozessklassen klarer voneinander abgegrenzt sind und konsistentere Muster zeigen.

Interpretation

Aus den Ergebnissen lassen sich zwei Modellierungsstrategien ableiten, abhängig von der gewünschten Prozessgranularität, den verfügbaren Eingabedaten und der erforderlichen Erkennungsleistung:

1. **Hierarchischer Bottom-up Ansatz:** Hauptaktivität und Lokalisierung → Feinprozess → Teilprozess → Grobprozess. Dieser Ansatz reduziert

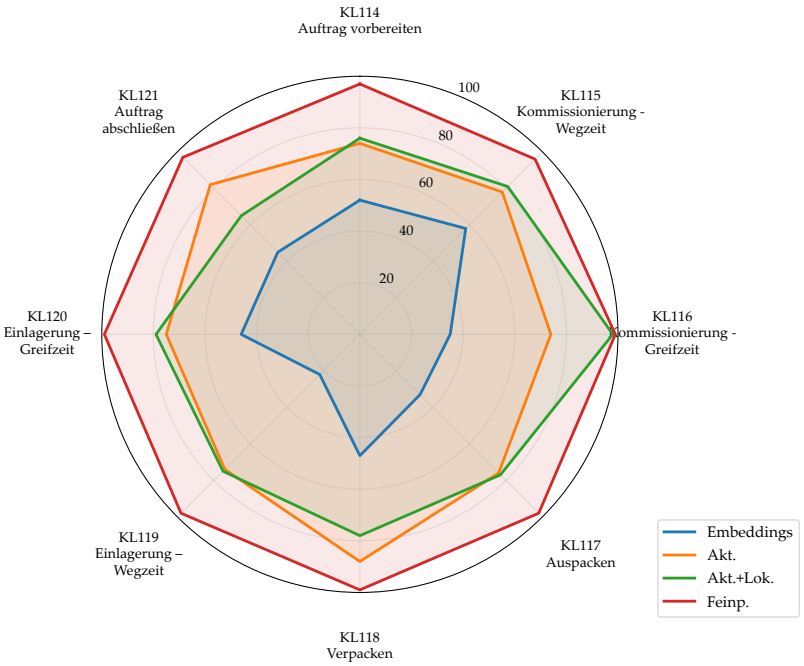


Abb. 6.3 Vergleich der Teilprozesserkennungsleistung von Transformer-Modellen für verschiedene Eingabemerkmalskonfigurationen (*Embeddings*, *Hauptaktivität*, *Hauptaktivität + Lokalisierung*, *Feinprozess*) auf Basis des klassenweisen F1-Maßes

die Modellkomplexität und verbessert die Interpretierbarkeit, erfordert jedoch weitere Verbesserungen bei der Erkennung von Feinprozessen.

2. **Direkte Modellierung von Prozessebenen:** Prozessebenen lassen sich direkt aus Hauptaktivitäten und Lokalisierung erkennen.

Implikationen für die Automatisierung von MTM und REFA-Zeitstudien

HAR ermöglicht die Automatisierung beobachtungsbasierter Analysen von menschlichen Bewegungen im Sinne der MTM-Verfahren (siehe Abschnitt 2.2.5). Die hier vorgestellte Prozesserkennung erweitert diesen Ansatz, indem Ist-Zeitdaten sensorbasiert erfasst und Ablaufabschnitte analog zur REFA-Zeitstudie (siehe Abschnitt 2.2.3) automatisch identifiziert werden. Damit adressiert das entwickelte Verfahren der Prozesserkennung zentrale Schwachstellen der manuellen Zeitstudie:

- Reduktion des Erfassungsaufwands durch sensorische Datenerhebung
- Skalierbarkeit auf große Mitarbeitergruppen und lange Beobachtungszeiträume
- Vermeidung der subjektiven Einflüsse bei der Leistungsgradbewertung

Gleichzeitig ist die Erkennungsleistung bei Feinprozessen ausbaufähig, und eine Validierung in realen industriellen Anwendungsszenarien steht aus.

Kapitel 7
Fazit und Ausblick

Das abschließende Kapitel fasst die folgenden drei Kernelemente der Arbeit zusammen und zeigt darauf aufbauend mögliche zukünftige Forschungsarbeiten zu diesen Aspekten auf:

1. Methode der **Datensatzerstellung** mit Framework und Checkliste
2. DaRA-**Datensatz**
3. Aktivitäts- und kontextsensitive **Prozesserkennung**

7.1 Datensatzerstellung | Framework und Checkliste

Fazit

Forschungsfrage 3 (siehe Abschnitt 1) wurde durch die Entwicklung eines auf Literatur- und Datensatzanalysen basierenden Frameworks beantwortet (siehe Abschnitt 4.3), das auf einheitlichen Taxonomien und empfohlenen Vorgehensweisen der HAR-Community beruht und eine systematische Datensatzerstellung ermöglicht. Als zentrales Ergebnis wird zudem eine Checkliste bereitgestellt (siehe Abschnitt 4.3.7), die als praktisches Werkzeug zur Verbesserung der Qualität und Standardisierung von Datensätzen dient.

Im Rahmen einer Umfrage wurde die Checkliste von den Autoren von acht Benchmark-Datensätzen retrospektiv auf ihre jeweiligen Datensätze angewendet (siehe Abschnitt 6.1). Die Ergebnisse dieser Evaluation bestätigen sowohl die Anwendbarkeit als auch die Relevanz der Checkliste. Gleichzeitig zeigte sich, dass viele bestehende Datensätze unzureichend dokumentiert und teilweise nicht mehr verfügbar sind, was die Verwendbarkeit und Reproduzierbarkeit negativ beeinflusst.

Die Überprüfung der Übertragbarkeit der Checkliste auf verwandte Anwendungsbereiche offenbarte auch Grenzen, insbesondere im Hinblick auf synthetisch generierte Bewegungsdaten sowie den Einsatz in Unternehmen. Insgesamt wird ein Großteil der empfohlenen Schritte in der industriellen Praxis häufig übersprungen; stattdessen liegt der Fokus auf der schnellen Er-

stellung von Datensätzen zur Erfüllung von Kundenanforderungen – oftmals zulasten der Modellqualität.

Ausblick

Diese Ergebnisse legen nahe, das Framework und die Checkliste kontinuierlich weiterzuentwickeln, um auch künftig den unterschiedlichen Anforderungen verschiedener Anwendungsbereiche und möglichen Veränderungen gerecht zu werden. Neben der Veröffentlichung von bewährten Verfahren ist eine Fehlerkultur zu fördern, in der diese systematisch dokumentiert werden. Eine solche Fehlersammlung könnte als wertvolle Ressource für Forscher dienen, die neue Datensätze erstellen, und die Qualität und Vergleichbarkeit der HAR-Forschung nachhaltig verbessern.

7.2 Datensatz | DaRA

Fazit

Forschungsfrage 2 (siehe Abschnitt 1) wurde durch den entwickelten DaRA-Datensatz beantwortet (siehe Abschnitt 5.1), einen neuartigen multimodalen Datensatz für die Intralogistik. Als erster Datensatz weltweit umfasst er verschiedene Sensortypen und umfangreiche Klassenlabels mit hoher Annotationsgüte, die sowohl menschliche Bewegungen als auch kontextuelle Informationen abbilden. Dadurch lassen sich Aktivitäten hinsichtlich ihres Inhalts, Ablaufs und ihrer räumlichen Umgebung charakterisieren.

Der Datensatz schließt wichtige Forschungslücken in HAR und HCR. Erstens mangelt es an Datensätzen, die speziell für den intralogistischen Bereich entwickelt wurden. Zweitens fehlen in bestehenden Datensätzen kontextbezogene Sensordaten oder Labels, die für ein umfassendes Verständnis der Aktivitäten unerlässlich sind. Schließlich verfügt DaRA über umfangreiche Metadaten, die in vergleichbaren Datensätzen selten vorliegen.

DaRA bietet detaillierte Sensordaten sowie mit Kappa-Werten von 78,27 % und 99,88 % eine *sehr gute* bis *perfekte* Labelgüte (siehe Abschnitt 6.2). Ein trainiertes TCNN erzielte ein F1-Maß von über 73,70 % für die Erkennung der Hauptaktivitäten und demonstrierte damit die erfolgreiche Klassifizierung menschlicher Bewegungen. Einschränkungen ergeben sich aus der Aufnahmeumgebung und den Charakteristiken der Probanden. Die teilweise kontrollierte Laborumgebung ermöglicht zwar realistische Bewegungen, spiegelt jedoch nicht vollständig die realen Lagerprozesse wider, da nur ausgewählte Prozesse und Technologien der Intralogistik abgedeckt werden. Ferner sind Frauen unter den Probanden unterrepräsentiert, und die Probanden waren keine professionellen Lagerarbeiter.

Ausblick

Der DaRA-Datensatz bietet ein Potenzial, das über die reine Anwendung in HAR und HCR hinausgeht. Zukünftige Arbeiten könnten diesen Datensatz gezielt nutzen, um weiterführende Fragestellungen zu adressieren. Dazu zählen etwa Logistiksimulationen zur Optimierung von Prozessen und Lagerlayoutgestaltung, Ansätze zur Bewegungsvorhersage oder die Extraktion von Skelettinformationen aus Videos zur Unterstützung simulationsbasierter Forschung und des robotischen Policy Learnings. Weiterhin eröffnet der Datensatz Perspektiven für Multi-Camera-Tracking, Personenidentifikation und -reidentifikation sowie die automatisierte Erkennung von Logistikobjekten. Exemplarische, rein explorative Anwendungsbeispiele sind in den Abbildungen A.15 und A.16 dargestellt. Auf Grundlage der vorhandenen Annotationen lassen sich zudem Studien zum zeitlichen Jitter von Bewegungslabeln durchführen. Weitere Forschungspotenziale bestehen in der Ableitung textbasierter Annotationen zur Verbesserung ihrer Interpretierbarkeit und der von Klassifikationsergebnissen.

7.3 Prozesserkennung | aktivitäts- und kontextsensitiv

Fazit

Forschungsfrage 1 (siehe Abschnitt 1) wurde durch die Entwicklung des ersten Verfahrens zur automatischen Prozesserkennung in der Intralogistik beantwortet. Das Verfahren basiert auf LSTM-, Transformer- und HMM-Sequenzmodellen (siehe Abschnitte 4.2 und 5.2) und wurde anhand des DaRA-Datensatzes evaluiert (siehe Abschnitt 6.3). Als Input dienten *Embeddings* sowie die Labels der Klassenkategorien *Hauptaktivität*, *Lokalisierung - Mensch* und der Prozesse.

Die Ergebnisse zeigen, dass das Transformer-Modell die höchste Erkennungsleistung erzielt. *Feinprozesse* konnten mit einem gewichteten F1-Maß von 58,67 % und *Teilprozesse* mit 78,65 % klassifiziert werden. Über alle untersuchten Modellklassen hinweg führte die Erweiterung der *Hauptaktivität* um *Lokalisierung - Mensch* konsistent zu einer Leistungssteigerung. Lokalisierungskontext stellt somit eine zentrale Information für die Modellierung industrieller Arbeitsprozesse dar.

Eine weitere zentrale Erkenntnis der Arbeit ist die beobachtete hierarchische Abhängigkeit innerhalb der Prozessstruktur: Aus *Feinprozessen* lassen sich *Teilprozesse* mit einem F1-Maß von 98,40 % und aus *Teilprozessen* wiederum *Grobprozesse* mit einem 95,18 % F1-Maß ableiten. Folglich ist die Prozesserkennung primär auf der niedrigsten Granularitätsebene (*Feinprozess*) zu erfolgen. Höhere Prozessebenen wie *Teil-* und *Grobprozesse* erfordern keine

separate Modellierung, sondern ergeben sich zuverlässig aus der Sequenz der *Feinprozesse*.

Damit wird ein hierarchischer Bottom-up Ansatz für die aktivitäts- und kontextsensitive Erkennung menschenzentrierter Prozesse begründet, der sowohl die Modellkomplexität reduziert als auch die Interpretierbarkeit der Ergebnisse verbessert.

Ausblick

Zukünftige Arbeiten haben die Übertragbarkeit des Verfahrens auf reale Unternehmensdaten systematisch zu untersuchen. Insbesondere gilt es zu klären, in welchem Umfang lagerspezifische Nachtrainingsstrategien erforderlich sind. Ansätze des unüberwachten Lernens könnten dabei lager- und anwendungsübergreifend zur Identifikation von Prozessclustern eingesetzt werden. Ergänzend könnten neben Aktivitäts- und Lokalisierungsinformationen auch BPMN-Modelle idealisierter Prozessabläufe als Eingabeparameter dienen, um die identifizierten Prozesscluster spezifischen prozessualen Klassen des BPMN zuzuordnen.

Weiterhin ermöglichen die erfolgreiche Prozesserkennung, Aktivitätserkennung und Indoorlokalisierung die Ableitung von Ablaufabschnitten nach dem REFA-Prinzip sowie die automatisierte Befüllung von Zeitaufnahmebögen. Erste Machbarkeitsstudien zeigen hierbei vielversprechende Ergebnisse beim Einsatz von Large Language Models.

Ein weiterer Forschungsschwerpunkt liegt in der automatischen Analyse von Prozessabweichungen. Auf Basis der erkannten Prozesssequenzen lassen sich Soll-Ist-Vergleiche durchführen und Anomalien im Arbeitsablauf identifizieren. Dadurch wird perspektivisch eine automatisierte Erkennung von ineffizienten Tätigkeiten und Arbeitsverschwendungen möglich. Langfristig wird so ein durchgängiger Kreislauf aus Datenerfassung, Prozesserkennung, verständlicher Aufbereitung, datengetriebener Arbeitsanalyse und Optimierung des realen Systems realisiert.

Literaturverzeichnis

[3DLife11] *3DLife ACM MM Grand Challenge 2011 - Realistic Interaction in Online Virtual Environments*. https://perso.telecom-paristech.fr/essid/3dlife-gc-11/. 2011.

[AAA21] Md Atiqur Rahman Ahad, Anindya Das Antar und Masud Ahmed. *IoT Sensor-Based Activity Recognition: Human Activity Recognition*. Intelligent Systems Reference Library. Cham: Springer International Publishing, 2021. DOI: 10.1007/978-3-030-51379-5.

[ABG22] Muhammad Haseeb Arshad, Muhammad Bilal und Abdullah Gani. „Human Activity Recognition: Review, Taxonomy and Open Challenges“. In: *Sensors* (2022). DOI: 10.3390/s22176463.

[ActionData04] *Action Database*. https://ppw.kuleuven.be/en/research/lep-old/lep-resources-old/action. 2004.

[AEG18] Sara Ashry, Reda Elbasiony und Walid Gomaa. „An LSTM-based Descriptor for Human Activities Recognition using IMU Sensors:“ In: *Proceedings of the 15th International Conference on Informatics in Control, Automation and Robotics*. Porto, Portugal: SCITEPRESS - Science und Technology Publications, 2018. DOI: 10.5220/0006902404940501.

[Agu+19] Antonio A. Aguileta u. a. „Multi-Sensor Fusion for Activity Recognition—A Survey“. In: *Sensors* (2019). DOI: 10.3390/s19173808.

[AK22] Skamo Aida und Jasmin Kevric. „Human Activity Recognition Using Ambient Sensor Data“. In: (2022). URL: https://doi.org/10.1016/j.ifacol.2022.06.016.

[Al +25] Fahmid Al Farid u. a. „A Structured and Methodological Review on Multi-View Human Activity Recognition for Ambient Assisted Living“. In: *Journal of Imaging* (2025). DOI: 10.3390/jimaging11060182.

[Ala+23] Gulzar Alam u. a. „Open Datasets in Human Activity Recognition Research—Issues and Challenges: A Review“. In: *IEEE Sensors Journal* (2023). DOI: 10.1109/JSEN.2023.3317645.

[Ali+21] Sayeda Shamma Alia u. a. *Bento Packaging Activity Recognition Challenge*. 2021. DOI: 10.21227/CWHS-T440.

[Als+20] Baha' A. Alsaify u. a. „A dataset for Wi-Fi-based human activity recognition in line-of-sight and non-line-of-sight indoor environments“. In: *Data in Brief* (2020). DOI: 10.1016/j.dib.2020.106534.

[Als20] Baha' A. Alsaify. *A dataset for Wi-Fi-based human activity recognition in line-of-sight and non-line-of-sight indoor environments*. 2020. DOI: 10.17632/V38WJMZ6F6.1.

[Alt90] Douglas G. Altman. *Practical Statistics for Medical Research*. Chapman und Hall/CRC, 1990. DOI: 10.1201/9780429258589.

[Ami22] Fatemeh Mohammadi Amin. *COVERED, CollabOratiVE Robot Environment Dataset for 3D Semantic segmentation*. 2022. URL: https://github.com/Fatemeh-MA/COVERED.

[AMW10] James M. Apple Jr., Russell D. Meller und John A. White Jr. *Empirically-Based Warehouse Design: Can Academics Accept Such an Approach?* Charlotte, NC: Material Handling Institute, 2010. ISBN: 978-1-882780-16-7.

[Ang+12] Davide Anguita u. a. „Human Activity Recognition on Smartphones Using a Multiclass Hardware-Friendly Support Vector Machine“. In: *Ambient Assisted Living and Home Care*. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. DOI: 10.1007/978-3-642-35395-6_30.

[Ang+13] D. Anguita u. a. „A Public Domain Dataset for Human Activity Recognition using Smartphones“. In: 2013. URL: https://api.semanticscholar.org/CorpusID:6975432.

[Ant20] S Antonino. „Umfrage: Produktionsunternehmen in Deutschland mit Nachholbedarf bei automatisierten Materialflusssystemen“. In: (2020). URL: https://www.interroll.com/de/news-events/pressemitteilungen/mitteilung/umfrage-produktionsunternehmen-in-deutschland-mit-nachholbedarf-bei-automatisierten-materialflusssystemen.

[Anvil14] *Anvil - The Video Annotation Research Tool*. https://www.anvil-software.de/. 2014.

[AP05] Olivier Aubert und Yannick Prié. „Advene: active reading through hypervideo“. In: *Proceedings of the sixteenth ACM conference on Hypertext and hypermedia*. Salzburg Austria, 2005. DOI: 10.1145/1083356.1083405.

[AR11] J.K. Aggarwal und M.S. Ryoo. „Human activity analysis: A review“. In: *ACM Computing Surveys* (2011). DOI: 10.1145/1922649.1922653.

[Ara+10] Mubashir Arain u. a. „What is a pilot or feasibility study? A review of current practice and editorial policy“. In: *BMC Medical Research Methodology* (2010). DOI: 10.1186/1471-2288-10-67.

[assembly22] *Assembly101: A Large-Scale Multi-View Video Dataset for Understanding Procedural Activities*. https://assembly-101.github.io/. 2022.

[ave19] avenix. *WDK/doc/images/1-DataAnnotationApp.png at master · avenix/WDK*. 2019. URL: https://github.com/avenix/WDK/blob/master/doc/images/1-DataAnnotationApp.png.

[Avs+21a] Hulya Avsar u. a. „Benchmarking Annotation Procedures for Multi-channel Time Series HAR Dataset“. In: *2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*. Kassel, Germany: IEEE, 2021. DOI: 10.1109/PerComWorkshops51409.2021.9431062.

[Avs+21b] Hülya Avsar u. a. „Cyber-physischer Zwilling Framework zur Generierung menschlicher Bewegungsdaten in der Intralogistik“. In: (2021). DOI: 10.2195/LJ_PROC_AVSAR_DE_202112_01.

[BA10] Billur Barshan und Kerem Altun. *Daily and Sports Activities*. 2010. DOI: 10.24432/C5C59F.

[Bac+10] M. Bachlin u. a. „Wearable Assistant for Parkinson's Disease Patients With the Freezing of Gait Symptom“. In: *IEEE Transactions on Information Technology in Biomedicine* (2010). DOI: 10.1109/TITB.2009.2036165.

[BAF25] Giulia Bassani, Carlo Alberto Avizzano und Alessandro Filippeschi. „Deep Learning Algorithms for Human Activity Recognition in Manual Material Handling Tasks“. In: *Sensors* (2025). DOI: 10.3390/s25216705.

[Ban+14a] Oresti Banos u. a. „Dealing with the Effects of Sensor Displacement in Wearable Activity Recognition“. In: *Sensors* (2014). DOI: 10.3390/s140609995.

[Ban+14b] Oresti Banos u. a. „mHealthDroid: A Novel Framework for Agile Development of Mobile Health Applications“. In: *Ambient Assisted Living and Daily Activities*. Cham: Springer International Publishing, 2014. DOI: 10.1007/978-3-319-13105-4_14.

[Bar+13] Thomas Bartscher u. a. *Kompakt-Lexikon Management*. Wiesbaden: Springer, 2013. DOI: 10.1007/978-3-658-03025-4.

[BAR21] Borja Bordel, Ramón Alcarria und Tomás Robles. „Recognizing human activities in Industry 4.0 scenarios through an analysis-modeling- recognition algorithm and context labels“. In: *Integrated Computer-Aided Engineering* (2021). DOI: 10.3233/ICA-210667.

[Bat+21] Edgar Batista u. a. „Sensors for Context-Aware Smart Healthcare: A Security Perspective“. In: *Sensors* (2021). DOI: 10.3390/s21206886.

[Bau+20] Tobias Baur u. a. „eXplainable Cooperative Machine Learning with NOVA“. In: *KI - Künstliche Intelligenz* (2020). DOI: 10.1007/s13218-020-00632-3.

[BB15] Henrik Blunck und Sourav Bhattacharya. *Heterogeneity Activity Recognition*. 2015. DOI: 10.24432/C5689X.

[BBS14] Andreas Bulling, Ulf Blanke und Bernt Schiele. „A tutorial on human activity recognition using body-worn inertial sensors“. In: *ACM Computing Surveys* (2014). DOI: 10.1145/2499621.

[BCD22] Luigi Bibbò, Riccardo Carotenuto und Francesco Della Corte. „An Overview of Indoor Localization System for Human Activity Recognition (HAR) in Healthcare“. In: *Sensors* (2022). DOI: 10.3390/s22218119.

[BCP20] Claudio Bettini, Gabriele Civitarese und Riccardo Presotto. „CAVIAR: Context-driven Active and Incremental Activity Recognition“. In: *Knowledge-Based Systems* (2020). DOI: 10.1016/j.knosys.2020.105816.

[Bed+20] Djamila Romaissa Beddiar u. a. „Vision-based human activity recognition: a survey“. In: *Multimedia Tools and Applications* (2020). DOI: 10.1007/s11042-020-09004-3.

[Beh+24] Maciej Behnke u. a. „Ethical Considerations and Checklist for Affective Research With Wearables“. In: *IEEE Transactions on Affective Computing* (2024). DOI: 10.1109/TAFFC.2022.3222524.

[Bel20] Jason Bell. *Machine learning: hands-on for developers and technical professionals*. John Wiley & Son Ltd, 2020. ISBN: 978-1-119-64214-5.

[Ben+21] Yizhak Ben-Shabat u. a. „The IKEA ASM Dataset: Understanding People Assembling Furniture through Actions, Objects and Pose“.

In: *IEEE Winter Conference on Applications of Computer Vision (WACV)*. Waikoloa, HI, USA, 2021. DOI: 10.1109/WACV48630.2021.00089.

[Ben+24] Toufik Benmessabih u. a. „Online human motion analysis in industrial context: A review“. In: *Engineering Applications of Artificial Intelligence* (2024). DOI: 10.1016/j.engappai.2024.107850.

[Bento21] *Bento Packaging Activity Recognition Challenge*. http://abc-research.github.io/bento2021/bento2021/data/. 2021.

[Bha+20] Ganapati Bhat u. a. „w-HAR: An Activity Recognition Dataset and Framework Using Low-Power Wearable Devices“. In: *Sensors* (2020). URL: https://doi.org/10.3390/s20185356.

[Bia+22] Sizhen Bian u. a. „The State-of-the-Art Sensing Techniques in Human Activity Recognition: A Survey“. In: *Sensors* (2022). DOI: 10.3390/s22124596.

[Bia+25] Sizhen Bian u. a. „Hybrid CNN-Dilated Self-attention Model Using Inertial and Body-Area Electrostatic Sensing for Gym Workout Recognition, Counting, and User Authentification“. In: 2025. DOI: 10.48550/arXiv.2503.06311.

[Bin10] Hartmut F. Binner. *Handbuch der prozessorientierten Arbeitsorganisation: Methoden und Werkzeuge zur Umsetzung*. REFA-Fachbuchreihe Unternehmensentwicklung. München: Hanser, 2010. ISBN: 978-3-446-42641-2.

[BL12] Rainer Bokranz und Kurt Landau. *Handbuch Industrial Engineering: Produktivitätsmanagement mit MTM. Band 1: Konzept*. OCLC: 820418782. Schäffer-Poeschel, 2012. ISBN: 978-3-7910-2863-7.

[BL25] Sizhen Bian und Paul Lukowicz. *RecGym: Gym Workouts Recognition Dataset with IMU and Capacitive Sensor*. 2025. DOI: 10.24432/C5PW4K.

[Boc+21] Marius Bock u. a. *Tutorial on Deep Learning for Human Activity Recognition*. 2021. DOI: 10.48550/ARXIV.2110.06663.

[Boc+22] Mohammud J. Bocus u. a. „OPERAnet, a multimodal activity recognition dataset acquired from radio frequency and vision-based sensors“. In: *Scientific Data* (2022). DOI: 10.1038/s41597-022-01573-2.

[Boc22] Mohammud Junaid Bocus. *A Comprehensive Multimodal Activity Recognition Dataset Acquired from Radio Frequency and Vision-Based Sensors*. 2022. DOI: 10.6084/M9.FIGSHARE.C.5551209.V1.

[BodyA09] *BodyAttack DataSet*. http://har-dataset.org/doku.php?id=wiki:dataset. 2009.

[BOKU25] *Ethics Committee::BOKU*. https://boku.ac.at/en/besondere-organe-und-einrichtungen/ethics-committee. 2025.

[Bon16] Tom Bonkenburg. „ROBOTICS IN LOGISTICS - A DPDHL perspective on implications and use cases for the logistics industry“. In: *DHL Customer Solutions & Innovation* (2016). URL: https://www.thehive-network.com/wp-content/uploads/2017/03/DHL_RoboticsInLogistics.pdf.

[BR04] Hennie Brugman und Albert Russel. „Annotating Multi-media/Multi-modal Resources with ELAN“. In: (2004). URL: https://scispace.com/pdf/annotating-multi-media-multi-modal-resources-with-elan-4r7hn5ax28.pdf.

[BTA12] Oresti Banos, Mate Toth und Oliver Amft. *REALDISP Activity Recognition Dataset*. 2012. DOI: 10.24432/C5GP6D.

[BVL2019] *Fokus auf Frauen in der Logistik*. https://transportlogistic.de/de/industry-insights/detail/frauen-in-der-logistik.html. 2019.

[BVL26] BVL-Bundesvereinigung Logistik e V. *Logistik - Bedeutung für die deutsche Wirtschaft - Die BVL: Das Logistik-Netzwerk für Fach- und Führungskräfte*. 2026. URL: https://www.bvl.de/service/zahlen-daten-fakten/umsatz-und-beschaeftigung (besucht am 24. 02. 2026).

[BY14] B. Barshan und M. C. Yuksek. „Recognizing Daily and Sports Activities in Two Open Source Machine Learning Environments Using Body-Worn Sensor Units". In: *The Computer Journal* (2014). DOI: 10.1093/comjnl/bxt075.

[CA18] Eduardo Casilari und Jose A.Santoyo-Ramón. *UMAFall: Fall Detection Dataset (Universidad de Malaga)*. 2018. DOI: 10.6084/M9.FIGSHARE.4214283.V7.

[Cas14] Pierluigi Casale. *User Identification From Walking Activity*. 2014. DOI: 10.24432/C5WC8S.

[CCT19] Diana Cook, Aaron Crandall und Brian Thomas. *Human Activity Recognition from Continuous Ambient Sensor Data*. 2019. DOI: 10.24432/C5D60P.

[Cha+21] S. Chan Chang u. a. „Capture-24: Activity tracker dataset for human activity recognition". In: (2021). URL: https://ora.ox.ac.uk/objects/uuid:99d7c092-d865-4a19-b096-cc16440cd001.

[Cha+24] Shing Chan u. a. „CAPTURE-24: A large dataset of wrist-worn activity tracker data collected in the wild for human activity recognition". In: *Scientific Data* (2024). DOI: 10.1038/s41597-024-03960-3.

[Cha23] Suvosree Chatterjee. *The Review of Human Activity Recognition Survey*. 2023. DOI: 10.20944/preprints202309.1939.v1.

[CHAD15] *Complex Human Activities Dataset (13 activities)*. https://www.utwente.nl/en/eemcs/ps/research/dataset/. 2015.

[Che+13a] Heng-Tze Cheng u. a. „NuActiv: recognizing unseen new activities using semantic attribute-based learning". In: *Proceeding of the 11th annual international conference on Mobile systems, applications, and services*. Taipei Taiwan: ACM, 2013. DOI: 10.1145/2462456.2464438.

[Che+13b] Heng-Tze Cheng u. a. „Towards zero-shot learning for human activity recognition using semantic attribute sequence model". In: *Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing*. Zurich Switzerland: ACM, 2013. DOI: 10.1145/2493432.2493511.

[Che+17] Lujie Chen u. a. „Supply chain collaboration for sustainability: A literature review and future research agenda". In: *International Journal of Production Economics* (2017). DOI: 10.1016/j.ijpe.2017.04.005.

[Che+18a] Changhao Chen u. a. *Dataset and Methods for Deep inertial Odometry*. 2018. URL: http://deepio.cs.ox.ac.uk/.

[Che+18b] Changhao Chen u. a. *OxIOD: The Dataset for Deep Inertial Odometry*. 2018. DOI: 10.48550/ARXIV.1809.07491.

[Chu+22] Seungeun Chung u. a. „Real-world multimodal lifelog dataset for human behavior study“. In: *ETRI Journal* (2022). DOI: 10.4218/etrij.2020-0446.

[Cic+22] Grazia Cicirelli u. a. „The HA4M dataset: Multi-Modal Monitoring of an assembly task for Human Action recognition in Manufacturing“. In: *Scientific Data* (2022). DOI: 10.1038/s41597-022-01843-z.

[CJK15a] Chen Chen, Roozbeh Jafari und Nasser Kehtarnavaz. *UTD Multimodal Human Action Dataset (UTD-MHAD)*. 2015. URL: https://personal.utdallas.edu/~kehtar/UTD-MHAD.html.

[CJK15b] Chen Chen, Roozbeh Jafari und Nasser Kehtarnavaz. „UTD-MHAD: A multimodal dataset for human action recognition utilizing a depth camera and a wearable inertial sensor“. In: *2015 IEEE International Conference on Image Processing (ICIP)*. Quebec City, QC, Canada: IEEE, 2015. DOI: 10.1109/ICIP.2015.7350781.

[CJK17] Chen Chen, Roozbeh Jafari und Nasser Kehtarnavaz. „A survey of depth and inertial sensor fusion for human action recognition“. In: *Multimedia Tools and Applications* (2017). DOI: 10.1007/s11042-015-3177-1.

[CK18] Roman Chereshnev und Attila Kertész-Farkas. „HuGaDB: Human Gait Database for Activity Recognition from Wearable Inertial Sensor Networks“. In: *Analysis of Images, Social Networks and Texts*. Series Title: Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018. DOI: 10.1007/978-3-319-73013-4_12.

[CMU23] *Carnegie Mellon University - CMU Graphics Lab - Motion Capture Library*. http://mocap.cs.cmu.edu/. 2003.

[CoAx21] *CoAx - Collaborative Action Dataset*. https://dlgmtzs.github.io/dataset-coax/. 2021.

[Coh60] Jacob Cohen. „A Coefficient of Agreement for Nominal Scales“. In: *Educational and Psychological Measurement* (1960). DOI: 10.1177/001316446002000104.

[Coo+25] William Coon u. a. „An Open Source and Freely Available Sleep Stage Classifier Optimized for Forehead EEG Devices“. In: *SLEEP* (2025). DOI: 10.1093/sleep/zsaf090.0437. URL: https://academic.oup.com/sleep/article/48/Supplement_1/A191/8134814.

[Cor+21] Kellie Corona u. a. „MEVA: A Large-Scale Multiview, Multimodal Video Dataset for Activity Detection“. In: *2021 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Waikoloa, HI, USA: IEEE, 2021. DOI: 10.1109/WACV48630.2021.00110.

[Cou16] Council for International Organizations of Medical Sciences (CIOMS). *International Ethical Guidelines for Health-related Research involving Humans*. Techn. Ber. Council for International Organizations of Medical Sciences (CIOMS), 2016. DOI: 10.56759/rgxl7405.

[Cou23] National Health and Medical Research Council. *National Statement on Ethical Conduct in Human Research 2023*. OCLC: 1410507182. Canberra ACT 2601, Australian Capital Territory: National Health und Medical Research Council, 2023. ISBN: 978-0-6484644-2-6.

[council19] *Tri-Council Policy Statement: Ethical Conduct for Research Involving Humans*. Secretariat on Responsible Conduct of Research, 2019.

[CP14] P. Casale und O. Pujol. *Activity Recognition from Single Chest-Mounted Accelerometer*. 2014. DOI: 10.24432/C56P5J.

[CPC85] C. J. Caspersen, K. E. Powell und G. M. Christenson. „Physical activity, exercise, and physical fitness: definitions and distinctions for health-related research". In: *Public Health Reports (Washington, D.C.: 1974)* (1985). ISSN: 0033-3549.

[CPR12] Pierluigi Casale, Oriol Pujol und Petia Radeva. „Personalization and user verification in wearable systems using biometric walking patterns". In: *Personal and Ubiquitous Computing* (2012). DOI: 10.1007/s00779-011-0415-z.

[CSC17] Eduardo Casilari, Jose A. Santoyo-Ramón und Jose M. Cano-García. „UMAFall: A Multisensor Dataset for the Research on Automatic Fall Detection". In: *Procedia Computer Science* (2017). DOI: 10.1016/j.procs.2017.06.110.

[CX15] Yuqing Chen und Yang Xue. „A Deep Learning Approach to Human Activity Recognition Based on Single Accelerometer". In: *2015 IEEE International Conference on Systems, Man, and Cybernetics*. Kowloon: IEEE, 2015. DOI: 10.1109/SMC.2015.263.

[Cza94] R. L. Czaplewski. *Variance approximations for assessments of classification accuracy*. Techn. Ber. RM-RP-316. Ft. Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Forest und Range Experiment Station, 1994. DOI: 10.2737/RM-RP-316.

[DailyLog16] *DataSet – Daily Log (ADL) (2016)*. https://www.uni-mannheim.de/dws/research/projects/activity-recognition/dataset/dataset-daily-log/. 2016.

[Dal+20a] Mejdi Dallel u. a. *InHARD - Industrial Human Action Recognition Dataset in the Context of Industrial Collaborative Robotics*. 2020. DOI: 10.5281/ZENODO.4003541.

[Dal+20b] Mejdi Dallel u. a. „InHARD - Industrial Human Action Recognition Dataset in the Context of Industrial Collaborative Robotics". In: *2020 IEEE International Conference on Human-Machine Systems (ICHMS)*. Rome, Italy: IEEE, 2020. DOI: 10.1109/ICHMS49158.2020.9209531.

[Dal+23] Mejdi Dallel u. a. „Digital twin of an industrial workstation: A novel method of an auto-labeled data generator using virtual reality for human action recognition in the context of human–robot collaboration". In: *Engineering Applications of Artificial Intelligence* (2023). DOI: 10.1016/j.engappai.2022.105655.

[Dam+22] Dima Damen u. a. „Rescaling Egocentric Vision: Collection, Pipeline and Challenges for EPIC-KITCHENS-100". In: *International Journal of Computer Vision* (2022). DOI: 10.1007/s11263-021-01531-2.

[Dav93] Thomas H. Davenport. *Process innovation: reengineering work through information technology*. Boston, Mass: Harvard Business School Press, 1993. ISBN: 978-0-87584-366-7.

[DC22] Onur Delikurt und Adnan Corum. „Importance of Same Day Delivery of Fast-Moving Consumer Goods for E-Commerce Companies".

In: *Proceedings of the International Conference on Industrial Engineering and Operations Management*. Rome, Europe: IEOM Society International, 2022. DOI: 10.46254/EU05.20220263.

[Dem+20] Florenc Demrozi u. a. „Human Activity Recognition Using Inertial, Physiological and Environmental Sensors: A Comprehensive Survey“. In: *IEEE Access* (2020). DOI: 10.1109/ACCESS.2020.3037715.

[Dem+23] Florenc Demrozi u. a. *A Comprehensive Review of Automated Data Annotation Techniques in Human Activity Recognition*. 2023. DOI: 10.48550/ARXIV.2307.05988.

[Deu+16] Jochen Deuse u. a. „Zeitwirtschaft in der industriellen Produktion“. In: *Die Primäre Produktion*. Springer, 2016. DOI: 10.1007/978-3-662-53212-6_10.

[Dey01] Anind K. Dey. „Understanding and Using Context“. In: *Personal and Ubiquitous Computing* (2001). DOI: 10.1007/s007790170019.

[Die+17] Alexander Diete u. a. „Recognizing Grabbing Actions from Inertial and Video Sensor Data in a Warehouse Scenario“. In: *Procedia Computer Science* (2017). DOI: 10.1016/j.procs.2017.06.071.

[DLR07] René De Koster, Tho Le-Duc und Kees Jan Roodbergen. „Design and control of warehouse order picking: A literature review“. In: *European Journal of Operational Research* (2007). DOI: 10.1016/j.ejor.2006.07.009.

[DM14] Data Citation Synthesis Group und Maryann Martone. *Joint Declaration of Data Citation Principles*. Techn. Ber. Force11, 2014. DOI: 10.25490/A97F-EGYK.

[Dön+23] Robin Dönnebrink u. a. „Miss-placement Prediction of Multiple On-body Devices for Human Activity Recognition“. In: *Proceedings of the 8th international Workshop on Sensor-Based Activity Recognition and Artificial Intelligence*. Lübeck Germany: ACM, 2023. DOI: 10.1145/3615834.3615838.

[Dou04] Paul Dourish. „What we talk about when we talk about context“. In: *Personal and Ubiquitous Computing* (2004). DOI: 10.1007/s00779-003-0253-8.

[DSS17] Alexander Diete, Timo Sztyler und Heiner Stuckenschmidt. „A smart data annotation tool for multi-sensor activity recognition“. In: *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*. Kona, HI: IEEE, 2017. DOI: 10.1109/PERCOMW.2017.7917542.

[ECM20] *Enhanced Collaborative Model (ECM) Anti-Human Trafficking Task Force Protocol Development Checklists*. https://www.theiacp.org/resources/document/enhanced-collaborative-model-ecm-anti-human-trafficking-task-force-protocol. 2020.

[Elk+24] Luisa Elke u. a. „Bewegungsdaten als Planungsgrundlage“. In: *Logistics Journal: Proceedings* (2024). Publisher: Logistics Journal: Proceedings. DOI: 10.2195/LJ_PROC_ELKE_DE_202410_01.

[Ema00] Ezekiel J. Emanuel. „What Makes Clinical Research Ethical?“ In: *JAMA* (2000). DOI: 10.1001/jama.283.20.2701.

[Ero17] Olga Erohin. *Wissensgewinnung durch Datenanalyse zur prospektiven Zeitermittlung*. Dortmund: Shaker Verlag, 2017. ISBN: 978-3-8440-5060-8.

[Ess+12] Slim Essid u. a. „A multi-modal dance corpus for research into interaction between humans in virtual environments“. In: *Journal on Multimodal User Interfaces* (2012). DOI: 10.1007/s12193-012-0109-5.

[ETRI21] *ETRI Lifelog Dataset 2020*. https://nanum.etri.re.kr/share/schung/ETRILifelogDataset2020?lang=En_us. 2021.

[Eur16] Europäische Union. *Verordnung (EU) 2016/679 des Europäischen Parlaments und des Rates vom 27. April 2016 zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG (Datenschutz-Grundverordnung)*. 2016. URL: https://eur-lex.europa.eu/eli/reg/2016/679/oj.

[Eur22a] Eurostat. *Businesses in the transportation and storage sector*. Statistik. 2022. URL: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Businesses_in_the_transportation_and_storage_sector (besucht am 24. 02. 2026).

[Eur22b] Eurostat. *Internet purchases by individuals (2020 onwards)*. 2022. DOI: 10.2908/ISOC_EC_IB20. URL: https://ec.europa.eu/eurostat/databrowser/product/page/ISOC_EC_IB20 (besucht am 24. 02. 2026).

[EvaI09] *HumanEva-I Dataset*. http://humaneva.is.tue.mpg.de/datasets_human_1. 2009.

[EvaII09] *HumanEva-2 Dataset*. http://humaneva.is.tue.mpg.de/datasets_human_2. 2009.

[ExtraSens16] *The ExtraSensory Dataset*. http://extrasensory.ucsd.edu/. 2016.

[Fai07] Ya. R. Faizulkhakov. „Time synchronization methods for wireless sensor networks: A survey“. In: *Programming and Computer Software* (2007). DOI: 10.1134/S0361768807040044.

[FALLUP18] *FALL-UP dataset*. http://sites.google.com/up.edu.mx/har-up/. 2018.

[Fay+17] Sébastien Faye u. a. „An Open Dataset for Human Activity Analysis using Smart Devices“. 2017. URL: https://hal.science/hal-01586802.

[Fel+16] Sascha Feldhorst u. a. „Motion Classification for Analyzing the Order Picking Process using Mobile Sensors - General Concepts, Case Studies and Empirical Evaluation:“ In: *Proceedings of the 5th International Conference on Pattern Recognition Applications and Methods*. Rome, Italy: SCITEPRESS - Science, 2016. DOI: 10.5220/0005828407060713.

[Fel18] Sascha Feldhorst. *Automatische Aktivitäts- und Kontexterkennung zur Analyse des Kommissionierprozesses*. Logistik für die Praxis. Dortmund: Praxiswissen Service, 2018. ISBN: 978-3-86975-139-9.

[Fle73] Joseph L. Fleiss. *Statistical methods for rates and proportions*. Wiley series in probability and mathematical statistics. New York: Wiley, 1973. ISBN: 978-0-471-26370-8.

[Foo20] Giles M. Foody. „Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps

obtained by image classification“. In: *Remote Sensing of Environment* (2020). DOI: 10.1016/j.rse.2019.111630.

[For+25] Abdur Forkan u. a. „Internet of Things Dataset for Human Operator Activity Recognition in Industrial Environment“. In: *Proceedings of the 34th ACM International Conference on Information and Knowledge Management*. Seoul Republic of Korea: ACM, 2025. DOI: 10.1145/3746252.3761649.

[FPV18] *DataSet – First-Person View (ADL) (2018)*. https://www.uni-mannheim.de/dws/research/projects/activity-recognition/dataset/dataset-first-person-view/. 2018.

[Fra02] Edward Frazelle. *World-class warehousing and material handling*. Logistics management library. New York: McGraw-Hill, 2002. ISBN: 978-0-07-137600-6.

[Fra18] Torsten Franzke. *Der Mensch als Faktor in der manuellen Kommissionierung*. Wiesbaden: Springer Fachmedien Wiesbaden, 2018. DOI: 10.1007/978-3-658-20469-3.

[Fri16] Werner Fricke. *Arbeits- und Zeitwirtschaft verstehen: von der Zeitstudie bis zur Abtaktung*. Norderstedt: BoD - Books on Demand, 2016. ISBN: 978-3-7431-6298-3.

[FRT09] Kilian Forster, Daniel Roggen und Gerhard Troster. „Unsupervised Classifier Self-Calibration through Repeated Context Occurences: Is there Robustness against Sensor Displacement to Gain?“ In: *2009 International Symposium on Wearable Computers*. Linz, Austria: IEEE, 2009. DOI: 10.1109/ISWC.2009.12.

[Fu+20] Biying Fu u. a. „Sensing Technology for Human Activity Recognition: A Comprehensive Survey“. In: *IEEE Access* (2020). DOI: 10.1109/ACCESS.2020.2991891.

[GDR20] Luis Claudio Gubert, Cristiano André Da Costa und Rodrigo Da Rosa Righi. „Context awareness in healthcare: a systematic literature review“. In: *Universal Access in the Information Society* (2020). DOI: 10.1007/s10209-019-00664-z.

[Geb+21] Timnit Gebru u. a. „Datasheets for datasets“. In: *Communications of the ACM* (2021). DOI: 10.1145/3458723.

[Gravity15] *Fall detection PoC on Android handheld and watch.* https://github.com/SINTEF-SIT/project_gravity. 2015.

[Grz+17] Rene Grzeszick u. a. „Deep Neural Network based Human Activity Recognition for the Order Picking Process“. In: *Proceedings of the 4th International Workshop on Sensor-based Activity Recognition and Interaction*. Rostock Germany: ACM, 2017. DOI: 10.1145/3134230.3134231.

[Gud05] Timm Gudehus. *Logistik*. Berlin, Heidelberg: Springer, 2005. DOI: 10.1007/3-540-27629-7.

[Gud10] Timm Gudehus. *Logistik: Grundlagen - Strategien - Anwendungen*. Berlin, Heidelberg: Springer, 2010. ISBN: 978-3-540-89388-2.

[Gum+17] Alfons Gummersbach u. a. *Produktionsmanagement*. Hamburg: Handwerk und Technik, 2017. ISBN: 978-3-582-02412-1.

[Hal69] Ernst Haller-Wedel. *Das Multimoment-Verfahren in Theorie und Praxis*. Statistische Verfahren für Arbeitsstudien und Fertigung, Prüf- und Meßtechnik. Hanser München, 1969.

[HandG13] *Hand Gesture*. https://github.com/andreas-bulling/ActRecTut. 2013.

[HDM05] *Mocap Database HDM05*. https://resources.mpi-inf.mpg.de/HDM05/. 2005.

[HDM12] *HDM12 Dance - Data Base of Tango Motion Capture*. https://cg.cs.uni-bonn.de/publication/voegele-2016-hdm12. 2012.

[Hei97] Klaus Heinz, Hrsg. *Prozeßkostenrechnung für die Logistik kleiner und mittlerer Unternehmen - Methodik und Fallbeispiele*. Betriebsmanagement. Dortmund: Verl. Praxiswissen, 1997. ISBN: 978-3-929443-95-0.

[HH06] Michael ten Hompel und Volker Heidenblut, Hrsg. *Abkurzungen, Definitionen und Erlauterungen der wichtigsten Begriffe aus Materialfluss und Logistik*. Berlin, Heidelberg, Germany: Springer, 2006. ISBN: 978-3-540-28581-6.

[HH11] Michael ten Hompel und Volker Heidenblut, Hrsg. *Taschenlexikon Logistik: Abkürzungen, Definitionen und Erläuterungen der wichtigsten Begriffe aus Materialfluss und Logistik*. VDI-Buch. Berlin, Heidelberg: Springer, 2011. ISBN: 978-3-642-19944-8.

[HO94] Klaus Heinz und Ralf Olbrich. *Planzeitermittlung*. München Wien: Hanser, 1994. ISBN: 978-3-446-17597-6.

[Hoe+23a] Alexander Hoelzemann u. a. „Hang-Time HAR: A Benchmark Dataset for Basketball Activity Recognition Using Wrist-Worn Inertial Sensors“. In: *Sensors* (2023). DOI: 10.3390/s23135879.

[Hoe+23b] Alexander Hoelzemann u. a. *Hang-Time HAR: A Benchmark Dataset for Basketball Activity Recognition using Wrist-worn Inertial Sensors*. 2023. DOI: 10.5281/ZENODO.7920485.

[Hom+25] Daniel Homm u. a. „IdentiARAT: Toward Automated Identification of Individual ARAT Items from Wearable Sensors“. In: *2025 International Conference On Rehabilitation Robotics (ICORR)*. Chicago, IL, USA: IEEE, 2025. DOI: 10.1109/ICORR66766.2025.11063056.

[HP25] *Research with Human Participants | Cornell Research Services*. https://researchservices.cornell.edu/compliance/human-research. 2025.

[HS07] Michael ten Hompel und Thorsten Schmidt. *Warehouse management: automation and organisation of warehouse and order picking systems*. Berlin Heidelberg: Springer, 2007. ISBN: 978-3-540-35218-1.

[HSD18] Michael ten Hompel, Thorsten Schmidt und Johannes Dregger. *Materialflusssysteme: Förder- und Lagertechnik*. VDI-Buch. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018. DOI: 10.1007/978-3-662-56181-2.

[HSP25a] *Policy on Human Subjects Research | Policies*. https://policies.northeastern.edu/policy505/. 2025.

[HSP25b] *Human Subjects Protections | Glossary | Research Ethics & Compliance*. https://research-compliance.umich.edu/glossary/human-subjects-protections. 2025.

[HSZ19] Zawar Hussain, Michael Sheng und Wei Emma Zhang. „Different Approaches for Human Activity Recognition: A Survey“. In: (2019). DOI: 10.48550/ARXIV.1906.05074.

[Hua+24] Yiran Huang u. a. „A Survey on Wearable Human Activity Recognition: Innovative Pipeline Development for Enhanced Research and Practice“. In: (2024). DOI: 10.5445/IR/1000169626.

[HuGaDB18] *HuGaDB*. https://github.com/romanchereshnev/HuGaDB. 2018.

[HuMoD15] *HuMoD Database - Human Motion Dynamics on Actuation Level*. https://www.informatik.tu-darmstadt.de/sim/forschung_sim/datensaetze_sim/humod_sim/index.de.jsp. 2015.

[Hut+21] Ben Hutchinson u. a. „Towards Accountability for Machine Learning Datasets: Practices from Software Engineering and Infrastructure“. In: *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*. Virtual Event Canada: ACM, 2021. DOI: 10.1145/3442188.3445918.

[Hut18] Matthew Hutson. „Artificial intelligence faces reproducibility crisis“. In: *Science* (2018). DOI: 10.1126/science.359.6377.725.

[HV24a] Alexander Hoelzemann und Kristof Van Laerhoven. „A matter of annotation: an empirical study on in situ and self-recall activity annotations from wearable sensors“. In: *Frontiers in Computer Science* (2024). URL: https://doi.org/10.3389/fcomp.2024.1379788.

[HV24b] Alexander Hölzemann und Kristof Van Laerhoven. *Self-Annotated Wearable Activity Data*. 2024. DOI: 10.5281/zenodo.7654683.

[ICH16] *ICH Harmonised Guideline: Integrated Addendum to ICH E6(R1): Guideline for Good Clinical Practice E6(R2)*. https://database.ich.org/sites/default/files/E6_R2_Addendum.pdf. 2016.

[Ick+22] Katja Ickstadt u. a. „Lernverfahren der Künstlichen Intelligenz zur Inwertsetzung von Daten: Automatisierte Erkennung und Prognose“. In: *Silicon Economy*. Hrsg. von Michael ten Hompel, Michael Henke und Boris Otto. Berlin, Heidelberg: Springer Berlin Heidelberg, 2022. DOI: 10.1007/978-3-662-63956-6_11.

[IDA22a] Francesco Iodice, Elena De Momi und Arash Ajoudani. „HRI30: An Action Recognition Dataset for Industrial Human-Robot Interaction“. In: *2022 26th International Conference on Pattern Recognition (ICPR)*. Montreal, QC, Canada: IEEE, 2022. DOI: 10.1109/ICPR56361.2022.9956300.

[IDA22b] Francesco Iodice, Elena De Momi und Arash Ajoudani. *HRI30: An Action Recognition Dataset for Industrial Human-Robot Interaction*. 2022. DOI: 10.5281/ZENODO.5833411.

[IKE13] Ozlem Durmaz Incel, Mustafa Kose und Cem Ersoy. „A Review and Taxonomy of Activity Recognition on Mobile Phones“. In: *BioNanoScience* (2013). DOI: 10.1007/s12668-013-0088-3.

[IKEA20] *IKEA Assembly Dataset*. https://ikeaasm.github.io/. 2020.

[InHARDDT22] *InHARD-DT - Industrial Human Action Recognition Dataset - Digital Twin*. https://zenodo.org/records/7644247. 2022.

[IPIN17] *IMU Dataset for Motion and Device Mode Classification*. https://www.dropbox.com/scl/fo/67eyiqf6k7cdi89jxzsgz/AEKgvnhIpUI8E_L-jVURnJI?rlkey=54egsqasqusk7u9aq3vuqxpge&e=1&dl=0. 2017.

[ISO9000] *ISO/DIS 9000:2025 - Qualitätsmanagement – Grundlagen und Begriffe*. Deutsches Institut für Normung. DIN, 2025.

[Jun+18] Wilfried Jungkind u. a. *Handbuch der Prozessoptimierung: Die richtigen Werkzeuge auswählen und zielsicher einsetzen*. München: Carl Hanser Verlag GmbH & Co. KG, 2018. DOI: 10.3139/9783446459342.

[Kac+22] Sylvia Kaczmarek u. a. „Dataset and Methods for Recognizing Care Activities“. In: *Proceedings of the 7th International Workshop on Sensor-based Activity Recognition and Artificial Intelligence*. Rostock Germany: ACM, 2022. DOI: 10.1145/3558884.3558891.

[Käd+17] Christoph Käding u. a. „Fine-Tuning Deep Neural Networks in Continuous Learning Scenarios“. In: *Computer Vision – ACCV 2016 Workshops*. Series Title: Lecture Notes in Computer Science. Springer International Publishing, 2017. DOI: 10.1007/978-3-319-54526-4_43.

[Kal+10] Boštjan Kaluža u. a. „An Agent-Based Approach to Care in Independent Living“. In: *Ambient Intelligence*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. DOI: 10.1007/978-3-642-16917-5_18.

[Kas+17] Parinaz Kasebzadeh u. a. „IMU dataset for motion and device mode classification“. In: *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*. Sapporo: IEEE, 2017. DOI: 10.1109/IPIN.2017.8115956.

[KB13] Barbara Kitchenham und Pearl Brereton. „A systematic review of systematic review process research in software engineering“. In: *Information and Software Technology* (2013). DOI: 10.1016/j.infsof.2013.07.010.

[KCA24] Pranjal Kumar, Siddhartha Chauhan und Lalit Kumar Awasthi. „Human Activity Recognition (HAR) Using Deep Learning: Review, Methodologies, Progress and Future Research Directions“. In: *Archives of Computational Methods in Engineering* (2024). DOI: 10.1007/s11831-023-09986-x.

[Kha+17] Rajiv Khanna u. a. *Scalable Greedy Feature Selection via Weak Submodularity*. 2017. DOI: 10.48550/ARXIV.1703.02723.

[Kip14] Michael Kipp. *ANVIL*. Oxford University Press, 2014. DOI: 10.1093/oxfordhb/9780199571932.013.024.

[Kit+09] Barbara Kitchenham u. a. „Systematic literature reviews in software engineering – A systematic literature review“. In: *Information and Software Technology* (2009). DOI: 10.1016/j.infsof.2008.09.009.

[Kit04] Barbara Kitchenham. „Procedures for Performing Systematic Reviews“. In: *Joint Technical Report* (2004). ISSN: 1353-7776. URL: http://www.inf.ufsc.br/~aldo.vw/kitchenham.pdf.

[KIT10] *KIT Whole-Body Human Motion Database*. https://motion-database.humanoids.kit.edu/. 2010.

[Kitch09] *Quality of Life Grand Challenge, Kitchen Dataset*. http://kitchen.cs.cmu.edu/. 2009.

[Kor+25] Jonas Koreis u. a. „We belong together - A system-level investigation regarding AGV-assisted order picking performance“. In: *International Journal of Production Economics* (2025). DOI: 10.1016/j.ijpe.2025.109527.

[KRK24] Harmandeep Kaur, Veenu Rani und Munish Kumar. „Human activity recognition: A comprehensive review“. In: *Expert Systems* (2024). DOI: 10.1111/exsy.13680.

[Krü+14] Frank Krüger u. a. „Computational State Space Models for Activity and Intention Recognition. A Feasibility Study“. In: *PLoS ONE* (2014). Hrsg. von Fabio Rapallo. DOI: 10.1371/journal.pone.0109381.

[KS22a] Prabhat Kumar und S. Suresh. „FLAAP: An Open Human Activity Recognition (HAR) Dataset for FLAAP: An Open Human Activity Recognition (HAR) Dataset for Learning and Finding the Associated Activity Patterns Learning and Finding the Associated Activity Patterns“. In: *Procedia Computer Science* (2022). DOI: 10.1016/j.procs.2022.10.208.

[KS22b] Prabhat Kumar und S. Suresh. *FLAAP: An open Human Activity Recognition (HAR) dataset for learning and finding the associated activity patterns*. 2022. DOI: 10.17632/bdng756rgw.1.

[KSG18] Lukas Köping, Kimiaki Shirahama und Marcin Grzegorzek. „A general framework for sensor-based human activity recognition“. In: *Computers in Biology and Medicine* (2018). DOI: 10.1016/j.compbiomed.2017.12.025.

[Kuh+23] Peter Kuhlang u. a. *Digitalisierung der MTM-Methoden - Perspektiven zur Gestaltung produktiver und ergonomiegerechter Arbeit in Produktion und Logistik*. MTM-Schriften Industrial Engineering. Hamburg: MTM Association e.V, 2023. ISBN: 978-3-945635-26-1.

[KWM11] Jennifer R. Kwapisz, Gary M. Weiss und Samuel A. Moore. „Activity recognition using cell phone accelerometers“. In: *ACM SIGKDD Explorations Newsletter* (2011). DOI: 10.1145/1964897.1964918.

[Lag+20] Paula Lago u. a. *A dataset for complex activity recognition withmicro and macro activities in a cooking scenario*. Version Number: 1. 2020. DOI: 10.48550/ARXIV.2006.10681.

[Lag+22] Dimitrios Lagamtzis u. a. „CoAx: Collaborative Action Dataset for Human Motion Forecasting in an Industrial Workspace:“ In: *Proceedings of the 14th International Conference on Agents and Artificial Intelligence*. Online Streaming, — Select a Country —: SCITEPRESS - Science und Technology Publications, 2022. DOI: 10.5220/0010775600003116.

[Lar+12] Óscar D. Lara u. a. „Centinela: A human activity recognition system based on acceleration and vital sign data“. In: *Pervasive and Mobile Computing* (2012). DOI: 10.1016/j.pmcj.2011.06.004.

[LB06] U. Lindemann und G. C. Baumberger. „Individualisierte Produkte“. In: *Individualisierte Produkte — Komplexität beherrschen in Entwicklung und Produktion*. Series Title: VDI-Buch. Berlin, Heidelberg: Springer, 2006. DOI: 10.1007/3-540-34274-5_2.

[LC11] Young-Seol Lee und Sung-Bae Cho. „Activity Recognition Using Hierarchical Hidden Markov Models on a Smartphone with 3D Accelerometer“. In: *Hybrid Artificial Intelligent Systems*. Series Title: Lecture

Notes in Computer Science. Berlin, Heidelberg: Springer, 2011. DOI: 10.1007/978-3-642-21219-2_58.

[LDK11] Andrew C. Leon, Lori L. Davis und Helena C. Kraemer. „The role and interpretation of pilot studies in clinical research“. In: *Journal of Psychiatric Research* (2011). DOI: 10.1016/j.jpsychires.2010.10.008.

[LDL16] Bruno Lotter, Jochen Deuse und Edwin Lotter. *Die Primäre Produktion: Ein praktischer Leitfaden zur verlustfreien Wert-schöpfung*. VDI-Buch. Springer, 2016. ISBN: 978-3-662-53211-9.

[LHS21] Hui Liu, Yale Hartmann und Tanja Schultz. „CSL-SHARE: A Multimodal Wearable Sensor-Based Human Activity Dataset“. In: *Frontiers in Computer Science* (2021). DOI: 10.3389/fcomp.2021.759136.

[Lig71] Richard J. Light. „Measures of response agreement for qualitative data: Some generalizations and alternatives.“ In: *Psychological Bulletin* (1971). DOI: 10.1037/h0031643.

[Liu+25] Jianhua Liu u. a. „Indoor Localization Methods for Smartphones with Multi-Source Sensors Fusion: Tasks, Challenges, Strategies, and Perspectives“. In: *Sensors* (2025). DOI: 10.3390/s25061806.

[LK23] Aleksej Logacjov und Atle Kongsvold. *HARTH*. 2023. DOI: 10.24432/C5NC90.

[LK77] J. Richard Landis und Gary G. Koch. „The Measurement of Observer Agreement for Categorical Data“. In: *Biometrics* (1977). DOI: 10.2307/2529310.

[LNH14] Christoph H. Lampert, Hannes Nickisch und Stefan Harmeling. „Attribute-Based Classification for Zero-Shot Visual Object Categorization“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2014). DOI: 10.1109/TPAMI.2013.140.

[Loc+11] Jeffrey W. Lockhart u. a. „Design considerations for the WISDM smart phone-based sensor mining architecture“. In: *Proceedings of the Fifth International Workshop on Knowledge Discovery from Sensor Data*. San Diego California: ACM, 2011. DOI: 10.1145/2003653.2003656.

[Log+21] Aleksej Logacjov u. a. „HARTH: A Human Activity Recognition Dataset for Machine Learning“. In: *Sensors* (2021). DOI: 10.3390/s21237853.

[LU23] Aleksej Logacjov und Astrid Ustad. *HAR70+*. 2023. DOI: 10.24432/C5CW3D.

[Lüd+21] Stefan Lüdtke u. a. *Human Activity Recognition using Attribute-Based Neural Networks and Context Information*. 2021. DOI: 10.48550/ARXIV.2111.04564.

[MADS17] *Martial Arts, Dancing and Sports Dataset*. http://visal.cs.cityu.edu.hk/research/mads/. 2017.

[Man+15] Christian Mandery u. a. „The KIT whole-body human motion database“. In: *2015 International Conference on Advanced Robotics (ICAR)*. Istanbul, Turkey: IEEE, 2015. DOI: 10.1109/ICAR.2015.7251476.

[Mar+19] Lourdes Martínez-Villaseñor u. a. „UP-Fall Detection Dataset: A Multimodal Approach“. In: *Sensors* (2019). DOI: 10.3390/s19091988.

[Mar+22] Roberto Marani u. a. *HA4M - Human Action Multi-Modal Monitoring in ManufacturingHA4M - Human Action Multi-Modal Monitoring in Manufacturing*. 2022. DOI: 10.57760/SCIENCEDB.01872.

[Mar+25] Luis Marquez-Carpintero u. a. *CADDI: An in-Class Activity Detection Dataset using IMU data from low-cost sensors*. 2025. DOI: 10.48550/ARXIV.2503.02853.

[Mar16] Heinrich Martin. *Transport- und Lagerlogistik*. Wiesbaden: Springer, 2016. DOI: 10.1007/978-3-658-14552-1.

[Mar21] Maryam Rezayati. *Physical Human-Robot Contact Detection*. 2021. DOI: 10.17632/CTW2256PHB.2.

[Mat23] Miguel Matey-Sanz. *Smartphone and smartwatch inertial measurements from heterogeneous subjects for human activity recognition.* 2023. DOI: 10.5281/ZENODO.8199665.

[Mau+19a] Pauline Maurice u. a. *AndyData-lab-onePerson*. 2019. DOI: 10.5281/ZENODO.3254403.

[Mau+19b] Pauline Maurice u. a. „Human movement and ergonomics: An industry-oriented dataset for collaborative robotics“. In: *The International Journal of Robotics Research* (2019). DOI: 10.1177/0278364919882089.

[MCG23] Miguel Matey-Sanz, Sven Casteleyn und Carlos Granell. „Dataset of inertial measurements of smartphones and smartwatches for human activity recognition“. In: *Data in Brief* (2023). DOI: 10.1016/j.dib.2023.109809.

[Men+20] Matteo Menolotto u. a. „Motion Capture Technology in Industrial Applications: A Systematic Review“. In: *Sensors* (2020). DOI: 10.3390/s20195687.

[Men+24] Ciro Mennella u. a. „Promoting fairness in activity recognition algorithms for patient's monitoring and evaluation systems in healthcare“. In: *Computers in Biology and Medicine* (2024). DOI: 10.1016/j.compbiomed.2024.108826.

[Meva25] *Mevadata*. https://mevadata.org/. 2025.

[MG18] Sara Ashry Mohammed und Walid Gomaa. *HAD-AW Data-set Benchmark For Human Activity Recognition Using Apple Watch*. 2018. DOI: 10.13140/RG.2.2.18186.57280.

[Min+20] L. Minh Dang u. a. „Sensor-based and vision-based human activity recognition: A comprehensive survey“. In: *Pattern Recognition* (2020). DOI: 10.1016/j.patcog.2020.107561.

[ML92] Robert A. Monserud und Rik Leemans. „Comparing global vegetation maps with the Kappa statistic“. In: *Ecological Modelling* (1992). DOI: 10.1016/0304-3800(92)90003-W.

[MMN17] Daniela Micucci, Marco Mobilio und Paolo Napoletano. „UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones“. In: *Applied Sciences* (2017). DOI: 10.3390/app7101101.

[Moh+20] Fatemeh Mohammadi Amin u. a. „A Mixed-Perception Approach for Safe Human–Robot Collaboration in Industrial Automation“. In: *Sensors* (2020). DOI: 10.3390/s20216347.

[Mor+23] Md Golam Morshed u. a. „Human Action Recognition: A Taxonomy-Based Survey, Updates, and Opportunities“. In: *Sensors* (2023). DOI: 10.3390/s23042182.

[Moy+18] Fernando Moya Rueda u. a. „Convolutional Neural Networks for Human Activity Recognition Using Body-Worn Sensors“. In: *Informatics* (2018). DOI: 10.3390/informatics5020026.

[Moy+26] Fernando Moya Rueda u. a. „Retrieval-Based Annotation for Multi-Channel Time Series Data of Human Activities“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Bd. 2706. Cham: Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_4.

[MP19] Lourdes Martínez-Villaseñor und Hiram Ponce. „A concise review on sensor signal acquisition and transformation applied to human activity recognition and human–robot interaction“. In: *International Journal of Distributed Sensor Networks* (2019). DOI: 10.1177/1550147719853987.

[MRS12] Corey McCall, Kishore Reddy und Mubarak Shah. „Macro-class selection for hierarchical k-nn classification of inertial sensor data“. In: *Proceedings of the 2nd International Conference on Pervasive Embedded Computing and Communication Systems*. Rome, Italy: SciTePress - Science, 2012. DOI: 10.5220/0003819101060114.

[MTM26] *MTM Datenkarten*. https://mtm.org/ueber-mtm/datenkarten. 2026.

[Mül+07] Meinard Müller u. a. „Documentation Mocap Database HDM05“. In: (2007). ISSN: 1610-8892. URL: https://resources.mpi-inf.mpg.de/HDM05/07_MuRoClEbKrWe_HDM05.pdf.

[Mun+22] Charith Munasinghe u. a. „COVERED, CollabOratiVE Robot Environment Dataset for 3D Semantic segmentation“. In: *2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA)*. Stuttgart, Germany: IEEE, 2022. DOI: 10.1109/ETFA52439.2022.9921525.

[Nai+23] Nilah Ravi Nair u. a. *Dataset Bias in Human Activity Recognition*. 2023. DOI: 10.48550/ARXIV.2301.10161.

[Nai+25] Nilah Ravi Nair u. a. „Representation Biases in Time-Series Human Activity Recognition with Small Sample Sizes“. In: *Pattern Recognition*. Cham: Springer Nature Switzerland, 2025. DOI: 10.1007/978-3-031-78354-8_3.

[Nap+24] Otávio Napoli u. a. „A benchmark for domain adaptation and generalization in smartphone-based human activity recognition“. In: *Scientific Data* (2024). DOI: 10.1038/s41597-024-03951-4.

[NCB18] Nipun D. Nath, Theodora Chaspari und Amir H. Behzadan. „Automated ergonomic risk monitoring using body-mounted sensors and machine learning“. In: *Advanced Engineering Informatics* (2018). DOI: 10.1016/j.aei.2018.08.020.

[Nie+20a] Friedrich Niemann u. a. „LARa: Creating a Dataset for Human Activity Recognition in Logistics Using Semantic Attributes“. In: *Sensors* (2020). DOI: 10.3390/s20154083.

[Nie+20b] Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 01) – A Motion Capture and Inertial Measurement Dataset*. 2020. DOI: 10.5281/ZENODO.3862782.

[Nie+20c] Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa) – A Motion Capture and Inertial Measurement Dataset*. 2020. DOI: 10.5281/ZENODO.3862781.

[Nie+21a] Friedrich Niemann u. a. *Context-Aware Activity Recognition in Logistics (CAARL) – A optical marker-based Motion Capture Dataset*. 2021. DOI: 10.5281/ZENODO.5680951.

[Nie+21b] Friedrich Niemann u. a. „Context-Aware Human Activity Recognition in Industrial Processes“. In: *Sensors* (2021). DOI: 10.3390/s22010134.

[Nie+22a] Friedrich Niemann u. a. „Applications of human activity recognition in industrial processes – Synergy of human and technology“. In: (2022). DOI: 10.48550/ARXIV.2212.02266.

[Nie+22b] Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 02) – A Motion Capture and Inertial Measurement Dataset*. 2022. DOI: 10.5281/ZENODO.5761276.

[Nie+23] Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 03) – A Motion Capture and Inertial Measurement Dataset*. 2023. DOI: 10.5281/ZENODO.8189341.

[Nie+26a] Friedrich Niemann u. a. „DaRA Dataset: Combining Wearable Sensors, Location Tracking, and Process Knowledge for Enhanced Human Activity and Human Context Recognition in Warehousing“. In: *Sensors* (2026). DOI: 10.3390/s26020739.

[Nie+26b] Friedrich Niemann u. a. *Data Fusion for advanced Research in industrial Applications (DaRA) – A Multi-Sensor, Multi-Level Annotated Dataset for Human Activity and Human Context Recognition in Warehousing*. 2026. DOI: 10.5281/ZENODO.10468175.

[Nie+26c] Friedrich Niemann u. a. *Test Annotations for Quality Evaluation of the DaRA Dataset – Annotated and Revised Video Data with Activity and Context Labels*. 2026. DOI: 10.5281/ZENODO.15118021.

[Nie+26d] Friedrich Niemann u. a. „Towards Standardized Dataset Creation for Human Activity Recognition: Framework, Taxonomy, Checklist, and Best Practices“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_5.

[Nil25] Niloy Sikder. *eegMobility_dataset*. 2025. DOI: 10.34740/KAGGLE/DSV/12525688.

[Nov+21] Pierre-Emmanuel Novac u. a. *UCA-EHAR*. 2021. DOI: 10.5281/ZENODO.5659335.

[Nov+22] Pierre-Emmanuel Novac u. a. „UCA-EHAR: A Dataset for Human Activity Recognition with Embedded AI on Smart Glasses“. In: *Applied Sciences* (2022). DOI: 10.3390/app12083849.

[NSA25] Bahareh Nikpour, Dimitrios Sinodinos und Narges Armanfard. „Deep Reinforcement Learning in Human Activity Recognition: A Sur-

vey and Outlook“. In: *IEEE Transactions on Neural Networks and Learning Systems* (2025). DOI: 10.1109/TNNLS.2024.3360990.

[NSR21] Abdullah-Al Nahid, Niloy Sikder und Ibrahim Rafi. *KU-HAR: Human Activity Recognition Dataset*. 2021. DOI: 10.17632/45F952Y38R.5.

[ÖB14] Ahmet Özdemir und Billur Barshan. „Detecting Falls with Wearable Sensors Using Machine Learning Techniques“. In: *Sensors* (2014). DOI: 10.3390/s140610691.

[OC24] Will Orr und Kate Crawford. „Building Better Datasets: Seven Recommendations for Responsible Design from Dataset Creators“. In: (2024). DOI: 10.48550/ARXIV.2409.00252.

[OECD13] *OECD Guidelines on the Protection of Privacy and Transborder Flows of Personal Data*. Organisation for Economic Co-operation und Development. 2013.

[Olb93] Ralf Olbrich. *Aufbau einer Zeitwirtschaft: Beschreibung der Vorgehensweise*. Wirtschaftsverlag Bachem, 1993. ISBN: 978-3-89172-258-9.

[Oll+22] Malte Ollenschläger u. a. „MaD GUI: An Open-Source Python Package for Annotation and Analysis of Time-Series Data“. In: *Sensors* (2022). DOI: 10.3390/s22155849.

[OOA24] Ugonna Oleh, Roman Obermaisser und Abu Shad Ahammed. „A Review of Recent Techniques for Human Activity Recognition: Multimodality, Reinforcement Learning, and Language Models“. In: *Algorithms* (2024). DOI: 10.3390/a17100434.

[Open17] *An Open Dataset for Human Activity Analysis - Data collected using Smartphone, Smartwatch and Smartglasses*. http://kaggle.com/sasanj/human-activity-smart-devices. 2017.

[OpenPack22] *OpenPack Dataset*. https://open-pack.github.io/. 2022.

[Opport12] *Activity Recognition Challenge | Opportunity*. http://www.opportunity-project.eu/challenge.html. 2012.

[OR16] Francisco Ordóñez und Daniel Roggen. „Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition“. In: *Sensors* (2016). DOI: 10.3390/s16010115.

[Ore14] Rafael Garcia Oresti Banos. *MHEALTH*. 2014. DOI: 10.24432/C5TW22.

[Pab+25] Jaime Pabón u. a. „A Comprehensive Dataset for Activity of Daily Living (ADL) Research Compiled by Unifying and Processing Multiple Data Sources“. In: *Journal of Personalized Medicine* (2025). DOI: 10.3390/jpm15050210.

[Pap+20] Marietta Papadatou-Pastou u. a. „Human handedness: A meta-analysis.“ In: *Psychological Bulletin* (2020). DOI: 10.1037/bul0000229.

[PARDUSS13] *Physical Activity Recognition Dataset Using Smartphone Sensors*. https://www.utwente.nl/en/eemcs/ps/research/dataset/. 2013.

[Pon+21] Aditya Ponnada u. a. „Signaligner Pro: A Tool to Explore and Annotate Multi-day Raw Accelerometer Data“. In: *2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*. Kassel, Germany: IEEE, 2021. DOI: 10.1109/PerComWorkshops51409.2021.9431110.

[PS09] Michael Pulverich und Jörg Schietinger, Hrsg. *Handbuch Kommissionierung: effizient picken und packen*. München: Vogel, 2009. ISBN: 978-3-574-26094-0.

[RA25] Fernando Moya Rueda und Moh'd Khier Al Kfari. *wilfer9008/Data4Sim*. 2025. URL: https://github.com/wilfer9008/Data4Sim.

[Rag+21] Francesco Ragusa u. a. „The MECCANO Dataset: Understanding Human-Object Interactions from Egocentric Videos in an Industrial-like Domain". In: *2021 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Waikoloa, HI, USA: IEEE, 2021. DOI: 10.1109/WACV48630.2021.00161.

[Ray23] Partha Pratim Ray. „ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope". In: *Internet of Things and Cyber-Physical Systems* (2023). DOI: 10.1016/j.iotcps.2023.04.003.

[RC15] Charissa Ann Ronao und Sung-Bae Cho. „Deep Convolutional Neural Networks for Human Activity Recognition with Smartphone Sensors". In: *Neural Information Processing*. Series Title: Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015. DOI: 10.1007/978-3-319-26561-2_6.

[RC16] Charissa Ann Ronao und Sung-Bae Cho. „Human activity recognition with smartphone sensors using deep learning neural networks". In: *Expert Systems with Applications* (2016). DOI: 10.1016/j.eswa.2016.04.032.

[RealWorld16] *DataSet – RealWorld (HAR) (2016)*. https://www.uni-mannheim.de/dws/research/projects/activity-recognition/dataset/dataset-realworld/. 2016.

[REF13] REFA. *REFA Kompakt-Grundausbildung 2.0 - Das Basis-Know-how in Industrial Engineering*. REFA Kompakt-Grundausbildung 2.0. 2013.

[REF21] REFA. *REFA-Grundausbildung 4.0 - Begriffe und Formeln*. REFA Kompendium Arbeitsorganisation. München: Hanser, 2021. ISBN: 978-3-446-47177-1.

[REF95] REFA, Hrsg. *Den Erfolg vereinbaren: Führen mit Zielvereinbarungen*. REFA-Fachbuchreihe Unternehmensentwicklung. München: Hanser, 1995. ISBN: 978-3-446-18407-7.

[REF97] REFA, Hrsg. *Datenermittlung*. Methodenlehre der Betriebsorganisation. Hanser, 1997. ISBN: 978-3-446-19059-7.

[Reh+24] Saeed Ur Rehman u. a. „Human Activity Recognition: A Comparative Study of Validation Methods and Impact of Feature Extraction in Wearable Sensors". In: *Algorithms* (2024). DOI: 10.3390/a17120556.

[Rei+18a] Christopher Reining u. a. „Attribute Representation for Human Activity Recognition of Manual Order Picking Activities". In: *Proceedings of the 5th International Workshop on Sensor-based Activity Recognition and Interaction*. Berlin Germany: ACM, 2018. DOI: 10.1145/3266157.3266214.

[Rei+18b] Christopher Reining u. a. „Towards a Framework for Semi-Automated Annotation of Human Order Picking Activities Using Motion Capturing". In: 2018. DOI: 10.15439/2018F188.

[Rei+19a] Christopher Reining u. a. „Human Activity Recognition for Production and Logistics—A Systematic Literature Review“. In: *Information* (2019). DOI: 10.3390/info10080245.

[Rei+19b] Attila Reiss u. a. „Deep PPG: Large-Scale Heart Rate Estimation with Convolutional Neural Networks“. In: *Sensors* (2019). DOI: 10.3390/s19143079.

[Rei+20] Christopher Reining u. a. „Annotation Performance for multi-channel time series HAR Dataset in Logistics“. In: *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*. Austin, TX, USA: IEEE, 2020. DOI: 10.1109/PerComWorkshops48775.2020.9156170.

[Rei+23] Christopher Reining u. a. „A Tutorial on Dataset Creation for Sensor-based Human Activity Recognition“. In: *2023 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*. IEEE, 2023. DOI: 10.1109/PerComWorkshops56833.2023.10150401.

[Rei12] Attila Reiss. *PAMAP2 Physical Activity Monitoring*. 2012. DOI: 10.24432/C5NW2H.

[Rei21] Christopher Reining. *Attributbasierte Erkennung menschlicher Aktivitäten in industriellen Prozessen am Beispiel der Logistik*. OCLC: 1282183543. Dortmund: Verlag Praxiswissen, 2021. ISBN: 978-3-86975-163-4.

[Ren+24] Yanling Ren u. a. „Clinical human activity recognition based on a wearable patch of combined tri-axial ACC and ECG sensors“. In: *DIGITAL HEALTH* (2024). DOI: 10.1177/20552076231223804.

[Rey+13] Jorge Reyes-Ortiz u. a. *Human Activity Recognition Using Smartphones*. 2013. DOI: 10.24432/C54S4K.

[Rey+15] Jorge Reyes-Ortiz u. a. *Smartphone-Based Recognition of Human Activities and Postural Transitions*. 2015. DOI: 10.24432/C54G7M.

[Rey+16] Jorge-L. Reyes-Ortiz u. a. „Transition-Aware Human Activity Recognition Using Smartphones“. In: *Neurocomputing* (2016). DOI: 10.1016/j.neucom.2015.07.085.

[RF18] Fernando Moya Rueda und Gernot A. Fink. „Learning Attribute Representation for Human Activity Recognition“. In: *2018 24th International Conference on Pattern Recognition (ICPR)*. Beijing: IEEE, 2018. DOI: 10.1109/ICPR.2018.8545146.

[RFF20] Francesco Ragusa, Antonino Furnari und Giovanni Maria Farinella. *MECCANO: A Multimodal Egocentric Dataset for Humans Behavior Understanding in the Industrial-like Domain*. 2020. URL: https://iplab.dmi.unict.it/MECCANO/.

[RGG12] Tobias Rammelmeier, Stefan Galka und Willibald A. Günthner. „Error Prevention in Manual Order Picking“. In: *Logistics Journal: Proceedings* (2012). DOI: 10.2195/LJ_PROC_RAMMELMEIER_DE_201210_01.

[Rhe+09] Ill-Keun Rhee u. a. „Clock Synchronization in Wireless Sensor Networks: An Overview“. In: *Sensors* (2009). DOI: 10.3390/s90100056.

[RI19] Attila Reiss und Ina Indlekofer. *PPG-DaLiA*. 2019. DOI: 10.24432/C53890.

[Rib+16] Daniele Riboni u. a. „Unsupervised recognition of interleaved activities of daily living through ontological and probabilistic reasoning“. In: *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. Heidelberg Germany: ACM, 2016. DOI: 10.1145/2971648.2971691.

[RN10] Prakash Ranganathan und Kendall Nygard. „Time Synchronization in Wireless Sensor Networks: A Survey“. In: *International Journal of UbiComp* (2010). DOI: 10.5121/iju.2010.1206.

[RN26a] Christopher Reining und Friedrich Niemann. *Kommissionierung - Systeme, Strategien und Technologien für effiziente Materialflusssysteme*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-70190-4.

[RN26b] Christopher Reining und Friedrich Niemann. *Order Picking - Systems, Strategies, and Technologies for Efficient Material Flow Systems*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-73391-2.

[Rog+10] Daniel Roggen u. a. „Collecting complex activity datasets in highly rich networked sensor environments“. In: *2010 Seventh International Conference on Networked Sensing Systems (INSS)*. Kassel, Germany: IEEE, 2010. DOI: 10.1109/INSS.2010.5573462.

[RP13] Daniel Roggen und Meir Plotnik. *Daphnet Freezing of Gait*. 2013. DOI: 10.24432/C56K78.

[RS12] Attila Reiss und Didier Stricker. „Introducing a New Benchmarked Dataset for Activity Monitoring“. In: *2012 16th International Symposium on Wearable Computers*. Newcastle, United Kingdom: IEEE, 2012. DOI: 10.1109/ISWC.2012.13.

[RS22] Eric Rosen und Doruk Senkal. *CHARM: A Hierarchical Deep Learning Model for Classification of Complex Human Activities Using Motion Sensors*. 2022. DOI: 10.48550/ARXIV.2207.07806.

[Rue+19] Fernando Moya Rueda u. a. „Combining Symbolic Reasoning and Deep Learning for Human Activity Recognition“. In: *2019 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*. Kyoto, Japan: IEEE, 2019. DOI: 10.1109/PERCOMW.2019.8730792.

[Rue+26] Fernando Moya Rueda u. a. „Activity- and Context-Sensitive Recognition of Human-Centered Processes in Warehousing“. In: *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2026)*. Status: eingereicht. Italien, 2026.

[Sac09] Reiner Sackermann. *Eine wissensbasierte Methode zur Zeitermittlung in der Einzel- und Kleinserienfertigung*. Schriftenreihe Industrial Engineering. Shaker, 2009. ISBN: 978-3-8322-8766-5.

[Sad07] Volker Sadowsky. „Beitrag zur analytischen Leistungsermittlung von Kommissioniersystemen“. In: (2007). DOI: 10.17877/DE290R-7231.

[SAD14] *Sensors activity dataset*. https://www.utwente.nl/en/eemcs/ps/research/dataset/. 2014.

[SAG25] Nazanin Sedaghati, Sondos Ardebili und Ali Ghaffari. „Application of human activity/action recognition: a review“. In: *Multimedia Tools and Applications* (2025). DOI: 10.1007/s11042-024-20576-2.

[Sah+24] Bidyut Saha u. a. „Personalized Human Activity Recognition: Real-time On-device Training and Inference“. In: *IEEE Consumer Electronics Magazine* (2024). DOI: 10.1109/MCE.2024.3398294.

[Sal+25a] Laura Saldaña-Aristizábal u. a. *Daily Activities Wearable Dataset for Cardiorespiratory Fitness Estimation*. 2025. DOI: 10.5281/zenodo.15769101.

[Sal+25b] Laura Saldaña-Aristizábal u. a. „Indirect AI-Based Estimation of Cardiorespiratory Fitness from Daily Activities Using Wearables“. In: *Electronics* (2025). DOI: 10.3390/electronics14153081.

[SB14] Shai Shalev-Shwartz und Shai Ben-David. *Understanding machine learning: from theory to algorithms*. Cambridge University Press, 2014. ISBN: 978-1-107-05713-5.

[SBB10] Leonid Sigal, Alexandru O. Balan und Michael J. Black. „HumanEva: Synchronized Video and Motion Capture Dataset and Baseline Algorithm for Evaluation of Articulated Human Motion“. In: *International Journal of Computer Vision* (2010). DOI: 10.1007/s11263-009-0273-6.

[SBG99] Albrecht Schmidt, Michael Beigl und Hans-W Gellersen. „There is more to context than location“. In: *Computers & Graphics* (1999). DOI: 10.1016/S0097-8493(99)00120-X.

[SBL18] Christopher Schlick, Ralph Bruder und Holger Luczak. „Arbeitswirtschaft“. In: *Arbeitswissenschaft*. Hrsg. von Christopher Schlick, Ralph Bruder und Holger Luczak. Springer, 2018. DOI: 10.1007/978-3-662-56037-2_7.

[Sch03] Joachim Schulte. „Auftragsstrukturen und Kosten der Aufbauorganisation“. In: (2003). URL: https://www.technische-logistik.net//node/16810 (besucht am 24. 02. 2026).

[SDH09] Ekaterina H. Spriggs, Fernando De La Torre und Martial Hebert. „Temporal segmentation and activity classification from first-person sensing“. In: *2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*. Miami, FL: IEEE, 2009. DOI: 10.1109/CVPRW.2009.5204354.

[Sen+21] Piotr Senkus u. a. „Process Definitions - Critical Literature Review“. In: *EUROPEAN RESEARCH STUDIES JOURNAL* (2021). DOI: 10.35808/ersj/2352.

[Sen+22] Fadime Sener u. a. „Assembly101: A Large-Scale Multi-View Video Dataset for Understanding Procedural Activities“. In: *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. New Orleans, LA, USA: IEEE, 2022. DOI: 10.1109/CVPR52688.2022.02042.

[Ses21] Arvind Seshan. *Enabling High-Accuracy Human Activity Recognition with Fine-Grained Indoor Localization*. Version Number: 1. 2021. DOI: 10.48550/ARXIV.2108.06838.

[Sev+26] Kamil Seval u. a. *Tool for calculation of Order Picking Systems (Version 2)*. 2026. DOI: 10.5281/ZENODO.17961327.

[SF09] Gil Silva und Diogo Ferreira. „Applying Hidden Markov Models to Process Mining“. In: (2009). DOI: 10.13140/2.1.4120.7689.

[SHD21] Morgan Klaus Scheuerman, Alex Hanna und Remi Denton. „Do Datasets Have Politics? Disciplinary Values in Computer Vision Dataset Development“. In: *Proceedings of the ACM on Human-Computer Interaction* CSCW2 (2021). DOI: 10.1145/3476058.

[She21] Freddie Sherratt. *Bath Natural Environment HAR Data Set*. 2021. DOI: 10.5281/zenodo.4390498.

[Shi+25] Jungpil Shin u. a. „A Comprehensive Methodological Survey of Human Activity Recognition Across Diverse Data Modalities“. In: *Sensors* (2025). DOI: 10.3390/s25134028.

[Sho+14] Muhammad Shoaib u. a. „Fusion of Smartphone Motion Sensors for Physical Activity Recognition“. In: *Sensors* (2014). DOI: 10.3390/s140610146.

[Sho+16] Muhammad Shoaib u. a. „Complex Human Activity Recognition Using Smartphone and Wrist-Worn Motion Sensors“. In: *Sensors* (2016). DOI: 10.3390/s16040426.

[Sie15] Del Siegle. *Research Ethics and Informed Consent | Educational Research Basics by Del Siegle*. 2015. URL: https://researchbasics.education.uconn.edu/ethics-and-informed-consent/.

[Signal17] *Signaligner Pro*. https://signaligner.org/. 2017.

[SIPI12] *The USC-SIPI Human Activity Dataset*. https://sipi.usc.edu/had/. 2012.

[SisFall17] *SisFall Original Dataset*. https://www.kaggle.com/datasets/nvnikhil0001/sis-fall-original-dataset. 2017.

[SK21] Yoli Shavit und Itzik Klein. „Boosting Inertial-Based Human Activity Recognition With Transformers“. In: *IEEE Access* (2021). DOI: 10.1109/ACCESS.2021.3070646.

[Skoda15] *Skoda Mini Checkpoint*. http://har-dataset.org/doku.php?id=wiki:dataset. 2015.

[SLV17] Angela Sucerquia, José López und Jesús Vargas-Bonilla. „SisFall: A Fall and Movement Dataset“. In: *Sensors* 17.1 (2017). DOI: 10.3390/s17010198.

[SN21] Niloy Sikder und Abdullah-Al Nahid. „KU-HAR: An open dataset for heterogeneous human activity recognition“. In: *Pattern Recognition Letters* (2021). DOI: 10.1016/j.patrec.2021.02.024.

[SN24] Kamil Seval und Friedrich Niemann. *Tool for calculation of Order-Picking Systems*. 2024. DOI: 10.5281/ZENODO.14163472.

[Sol+15] Tomi Solakivi u. a. „Finland state of logistics 2014“. In: 2015. ISBN: 978-952-249-458-0.

[Sol+23] Tomi Solakivi u. a. „LOGISTIIKKASELVITYS 2023“. In: 2023. ISBN: 978-952-249-647-8.

[Sou+19] Wesllen Sousa Lima u. a. „Human Activity Recognition Using Inertial Sensors in a Smartphone: An Overview“. In: *Sensors* (2019). DOI: 10.3390/s19143213.

[SP08] Frank Straube und Hans-Christian Pfohl. *Trends und Strategien in der Logistik: globale Netzwerke im Wandel ; Umwelt, Sicherheit, Internationalisierung, Menschen*. Hamburg: DVV Media Group, Dt. Verkehrs-Verl, 2008. ISBN: 978-3-87154-388-3.

[SPI21] Freddie Sherrat, Andrew Plummer und Pejman Iravani. „Understanding LSTM Network Behaviour of IMU-Based Locomotion Mode Recognition for Applications in Prostheses and Wearables“. In: *Sensors 2021* (2021). DOI: 10.3390/s21041264.

[SR12] Pekka Siirtola und Juha Röning. „Recognizing Human Activities User-independently on Smartphones Based on Accelerometer Data“. In: *International Journal of Interactive Multimedia and Artificial Intelligence* (2012). DOI: 10.9781/ijimai.2012.155.

[SS16] Timo Sztyler und Heiner Stuckenschmidt. „On-body localization of wearable devices: An investigation of position-aware activity recognition“. In: *2016 IEEE International Conference on Pervasive Computing and Communications (PerCom)*. Sydney, Australia: IEEE, 2016. DOI: 10.1109/PERCOM.2016.7456521.

[SS24] Bidyut Saha und Riya Samanta. *BandX-Activity: Human Activity Recognition Dataset with Demographics Using the MPU6050 Sensor*. 2024. DOI: 10.5281/zenodo.14543551.

[SSH13] Muhammad Shoaib, Hans Scholten und P.J.M. Havinga. „Towards Physical Activity Recognition Using Smartphone Sensors“. In: *2013 IEEE 10th International Conference on Ubiquitous Intelligence and Computing and 2013 IEEE 10th International Conference on Autonomic and Trusted Computing*. Italy: IEEE, 2013. DOI: 10.1109/UIC-ATC.2013.43.

[Sta+26] Marta Starostka-Patyk u. a. „Human Activity Recognition (HAR) in Management of Logistics Processes: New Opportunities or Technology without Application?“ In: *Artificial Intelligence for Knowledge Acquisition and Management*. Cham: Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-18920-2_22.

[Sta21] Statistisches Bundesamt. *Brancheninformationen*. Statistik. 2021. URL: https://www.destatis.de/DE/Themen/Wirtschaft/Preise/Erzeugerpreisindex-Dienstleistungen/Methoden/brancheninformationen.html (besucht am 24. 02. 2026).

[Sta25] Statistisches Bundesamt. *Erwerbstätige, Arbeitnehmer, Selbständige und mithelfende Familienangehörige (im Inland): Deutschland, Jahre, Wirtschaftszweige*. Statistik. Arbeitskreis Ërwerbstätigenrechnung des Bundes und der Länder"Code: 13311-0001. 2025. URL: https://www-genesis.destatis.de/datenbank/online/statistic/13311/table/13311-0001/search/s/bGFnZXJlaQ%3D%3D (besucht am 24. 02. 2026).

[Sti+15] Allan Stisen u. a. „Smart Devices are Different: Assessing and MitigatingMobile Sensing Heterogeneities for Activity Recognition“. In: *Proceedings of the 13th ACM Conference on Embedded Networked Sensor Systems*. Seoul South Korea: ACM, 2015. DOI: 10.1145/2809695.2809718.

[Stu+23] Fabian Sturm u. a. „Challenges of the Creation of a Dataset for Vision Based Human Hand Action Recognition in Industrial Assembly“. In:

Intelligent Computing. Cham: Springer Nature Switzerland, 2023. DOI: 10.1007/978-3-031-37717-4_70.

[Szt+16] Timo Sztyler u. a. „Self-tracking Reloaded: Applying Process Mining to Personalized Health Care from Labeled Sensor Data“. In: *Transactions on Petri Nets and Other Models of Concurrency XI*. Bd. 9930. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016. DOI: 10.1007/978-3-662-53401-4_8.

[TAICHI18] *UMONS-TAICHI: A Multimodal Motion Capture Dataset of Expertise in Taijiquan Gestures*. https://github.com/numediart/UMONS-TAICHI. 2018.

[Tam+21] Christian Tamantini u. a. „The WGD—A Dataset of Assembly Line Working Gestures for Ergonomic Analysis and Work-Related Injuries Prevention“. In: *Sensors* (2021). DOI: 10.3390/s21227600.

[Tay+18] Jawad Tayyub u. a. „Learning Hierarchical Models of Complex Daily Activities from Annotated Videos“. In: *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Lake Tahoe, NV: IEEE, 2018. DOI: 10.1109/WACV.2018.00182.

[Tay22] Frederick Winslow Taylor. *Die Grundsätze wissenschaftlicher Betriebsführung: (The Principles of Scientific Management)*. De Gruyter, 1922. ISBN: 978-3-486-74743-0.

[TH07] Theodoros Theodoridis und Huosheng Hu. „Action classification of 3D human models using dynamic ANNs for mobile robot surveillance“. In: *2007 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. Sanya, China: IEEE, 2007. DOI: 10.1109/ROBIO.2007.4522190.

[Tha+10] Lehana Thabane u. a. „A tutorial on pilot studies: the what, why and how“. In: *BMC Medical Research Methodology* (2010). DOI: 10.1186/1471-2288-10-1.

[THC17] Jawad Tayyub, Majd Hawasly und Anthony George Cohn. *Complex and Long Activities Dataset*. 2017. DOI: 10.5518/249.

[The11] Theo Theodoridis. *Vicon Physical Action Data Set*. 2011. DOI: 10.24432/C5MG7Z.

[Tit+18] Mickaël Tits u. a. „UMONS-TAICHI: A multimodal motion capture dataset of expertise in Taijiquan gestures“. In: *Data in Brief* (2018). DOI: 10.1016/j.dib.2018.05.088.

[Tom+10] Jim Tompkins u. a. *Facilities planning*. Hoboken, NJ: Wiley, 2010. ISBN: 978-0-470-44404-7.

[Ton+18] Emma L. Tonkin u. a. „Talk, Text, Tag? Understanding Self-Annotation of Smart Home Data from a User's Perspective“. In: *Sensors* (2018). DOI: 10.3390/s18072365.

[TotalCap17] *UMONS-TAICHI: A Multimodal Motion Capture Dataset of Expertise in Taijiquan Gestures*. http://cvssp.org/data/totalcapture/. 2017.

[Tra+26] Hoan Tran u. a. „Towards Practical, Best Practice Video Annotation to Support Human Activity Recognition“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Series Title: Communications in Computer and Information Science. Cham: Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_6.

[Tru+17] Matthew Trumble u. a. „Total Capture: 3D Human Pose Estimation Fusing Video and Inertial Sensors“. In: *Procedings of the British Machine Vision Conference 2017*. London, UK: British Machine Vision Association, 2017. DOI: 10.5244/C.31.14.

[UC13] Wallace Ugulino und Débora Cardador. *Wearable Computing: Classification of Body Postures and Movements (PUC-Rio)*. 2013. DOI: 10.24432/C54W37.

[UCF11] *UCF-iPhone Data Set*. https://www.crcv.ucf.edu/data/UCF-iPhone.php. 2011.

[Ugu+12] Wallace Ugulino u. a. „Wearable Computing: Accelerometers' Data Classification of Body Postures and Movements“. In: *Advances in Artificial Intelligence - SBIA 2012*. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2012. DOI: 10.1007/978-3-642-34459-6_6.

[UIPRMD17] *UI-PRMD*. https://www.kaggle.com/datasets/liza5757/uiprmd. 2017.

[UniMiB17] *UniMiB SHAR Dataset*. https://www.kaggle.com/datasets/wangboluo/unimib-shar-dataset. 2017.

[Ust+23] Astrid Ustad u. a. „Validation of an Activity Type Recognition Model Classifying Daily Physical Behavior in Older Adults: The HAR70+ Model“. In: *Sensors* (2023). DOI: 10.3390/s23052368.

[Vak+18] Aleksandar Vakanski u. a. „A Data Set of Human Body Movements for Physical Rehabilitation Exercises“. In: *Data* (2018). DOI: 10.3390/data3010002.

[VCT19] Stacy A. Voccia, Ann Melissa Campbell und Barrett W. Thomas. „The Same-Day Delivery Problem for Online Purchases“. In: *Transportation Science* (2019). DOI: 10.1287/trsc.2016.0732.

[VDI3590-1] *VDI 3590 Blatt 1:1994-04 - Kommissioniersysteme; Grundlagen*. Verein Deutscher Ingenieure. Beuth, 1994.

[VDI4481] *VDI 4481:2019-04 - Personalbedarfsermittlung in der Kommissionierung*. Verein Deutscher Ingenieure. Beuth, 2019.

[VEL17] Yonatan Vaizman, Katherine Ellis und Gert Lanckriet. „Recognizing Detailed Human Context in the Wild from Smartphones and Smartwatches“. In: *IEEE Pervasive Computing* (2017). DOI: 10.1109/MPRV.2017.3971131.

[VH02] Edwin Van Teijlingen und Vanora Hundley. „The importance of pilot studies“. In: *Nursing Standard* (2002). DOI: 10.7748/ns2002.06.16.40.33.c3214.

[Vid+10] Vedrana Vidulin u. a. *Localization Data for Person Activity*. 2010. DOI: 10.24432/C57G8X.

[Vil+15] Thomas Vilarinho u. a. „A Combined Smartphone and Smartwatch Fall Detection System“. In: *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*. LIVERPOOL, United Kingdom: IEEE, 2015. DOI: 10.1109/CIT/IUCC/DASC/PICOM.2015.216.

[VK12] Anna Vögele und Björn Krüger. *HDM12 Dance*. 2012. URL: https://cg.cs.uni-bonn.de/publication/voegele-2016-hdm12.

[VK16] Anna Vögele und Björn Krüger. *HDM12 Dance - Documentation on a Data Base of Tango Motion Capture*. Techn. Ber. CG-2016-1. Bonn: University of Bonn, 2016. URL: https://cg.cs.uni-bonn.de/backend/v1/files/publications/HDM12_Dance_compressed.pdf.

[VNK15] Michalis Vrigkas, Christophoros Nikou und Ioannis A. Kakadiaris. „A Review of Human Activity Recognition Methods“. In: *Frontiers in Robotics and AI* (2015). DOI: 10.3389/frobt.2015.00028.

[VV04] Jan Vanrie und Karl Verfaillie. „Perception of biological motion: A stimulus set of human point-light actions“. In: *Behavior Research Methods, Instruments, & Computers* (2004). DOI: 10.3758/BF03206542.

[WARD08] *WARD - Distributed Human Action Recognition via Wearable Motion Sensor Networks*. https://people.eecs.berkeley.edu/~yang/software/WAR/. 2008.

[Wes07] Mathias Weske. *Business Process Management: Concepts, Languages, Architectures*. Berlin, Heidelberg: Springer, 2007. DOI: 10.1007/978-3-540-73522-9.

[Whi87] R.M. White. „A Sensor Classification Scheme“. In: *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control* (1987). DOI: 10.1109/T-UFFC.1987.26922.

[Wil+16] Mark D. Wilkinson u. a. „The FAIR Guiding Principles for scientific data management and stewardship“. In: *Scientific Data* (2016). DOI: 10.1038/sdata.2016.18.

[Win+22] Sven Winkelhaus u. a. „Hybrid order picking: A simulation model of a joint manual and autonomous order picking system“. In: *Computers & Industrial Engineering* (2022). DOI: 10.1016/j.cie.2022.107981.

[WISDM12] *WISDM Lab: Activity Prediction Dataset*. http://www.cis.fordham.edu/wisdm/dataset.php. 2012.

[WISDM13] *WISDM Lab: Actitracker Dataset*. http://www.cis.fordham.edu/wisdm/dataset.php. 2013.

[Wit+06] Peter Wittenburg u. a. „ELAN: a Professional Framework for Multimodality Research“. In: (2006). URL: http://www.lrec-conf.org/proceedings/lrec2006/pdf/153_pdf.pdf.

[WMK24] Linda Maria Wings, Eva Mazur und Veronika Kretschmer. *Light it Up! Integrationsleitfaden von Pick-by-Light für die Kommissionierung*. 2024. DOI: 10.24406/PUBLICA-4172.

[Wor13] World Medical Association (WMA). *Declaration of Helsinki: Ethical Principles for Medical Research Involving Human Subjects*. Techn. Ber. Fortaleza, Brazil, 2013. URL: https://www.wma.net/policies-post/wma-declaration-of-helsinki-ethical-principles-for-medical-research-involving-human-subjects/.

[Worker25] *A Dataset for Assessing Worker Activities in Industrial Settings*. https://digitalinnovationlab.github.io/mppdataset. 2025.

[Woz+17] Przemyslaw Woznowski u. a. *Talk, text or tag? The development of a self-annotation app for activity recognition in smart environments*. 2017.

[WS14] Alexandra Wunderle und Tobias Sommer. „Erfahrung und Augenmaß zählen“. In: *Hebezeuge Fördermittel* (2014).

[WV15] Janis Wojtusch und Oskar Von Stryk. „HuMoD - A versatile and open database for the investigation, modeling and simulation of human motion dynamics on actuation level“. In: *2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids)*. Seoul, South Korea: IEEE, 2015. DOI: 10.1109/HUMANOIDS.2015.7363534.

[WW25] Chung Lai Johnny Wan und Yulan Wang. „Logistics Management and Distribution Strategies“. In: *International Operations Management: Concepts and Applications*. Singapore: Springer Nature Singapore, 2025. DOI: 10.1007/978-981-96-6665-2_7.

[Xia+25] Qingxin Xia u. a. „Self-Supervised Learning for Complex Activity Recognition Through Motif Identification Learning“. In: *IEEE Transactions on Mobile Computing* (2025). DOI: 10.1109/TMC.2024.3514736.

[Yag+20] Ehsan Yaghoubi u. a. „Human Attribute Recognition— A Comprehensive Survey“. In: *Applied Sciences* (2020). DOI: 10.3390/app10165608.

[Yan+08] Allen Y. Yang u. a. „Distributed segmentation and classification of human actions using a wearable motion sensor network“. In: *2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*. Anchorage, AK, USA: IEEE, 2008. DOI: 10.1109/CVPRW.2008.4563176.

[Yao+18] Rui Yao u. a. „Efficient dense labelling of human activity sequences from wearables using fully convolutional networks“. In: *Pattern Recognition* (2018). DOI: 10.1016/j.patcog.2017.12.024.

[YKK18] Kristina Yordanova, Frank Krüger und Thomas Kirste. *Semantic Annotation for the CMU-MMAC Dataset*. 2018. DOI: 10.18453/ROSDOK_ID00000163.

[YLC20] Bruce Yu, Yan Liu und Keith Chan. „A Survey of Sensor Modalities for Human Activity Recognition:“ In: *Proceedings of the 12th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management*. Budapest, Hungary: SCITEPRESS - Science und Technology Publications, 2020. DOI: 10.5220/0010145202820294.

[Yos+24] Naoya Yoshimura u. a. „OpenPack: A Large-Scale Dataset for Recognizing Packaging Works in IoT-Enabled Logistic Environments“. In: *2024 IEEE International Conference on Pervasive Computing and Communications (PerCom)*. Biarritz, France: IEEE, 2024. DOI: 10.1109/PerCom59722.2024.10494448.

[Zap+08] Piero Zappi u. a. „Activity Recognition from On-Body Sensors: Accuracy-Power Trade-Off by Dynamic Sensor Selection“. In: *Wireless Sensor Networks*. Hrsg. von Roberto Verdone. Series Title: Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2008. DOI: 10.1007/978-3-540-77690-1_2.

[ZB14] Ahmet Zdemir und Billur Barshan. *Simulated Falls and Daily Living Activities Data Set*. 2014. DOI: 10.24432/C52028.

[ZCS19] Qingchang Zhu, Zhenghua Chen und Yeng Chai Soh. „A Novel Semisupervised Deep Learning Method for Human Activity Reco-

gnition“. In: *IEEE Transactions on Industrial Informatics* (2019). DOI: 10.1109/TII.2018.2889315.

[Zha+17] Weichen Zhang u. a. „Martial Arts, Dancing and Sports dataset: A challenging stereo and multi-view dataset for 3D human pose estimation“. In: *Image and Vision Computing* (2017). DOI: 10.1016/j.imavis.2017.02.002.

[Zha+22] Shibo Zhang u. a. „Deep Learning in Human Activity Recognition with Wearable Sensors: A Review on Advances“. In: *Sensors* (2022). DOI: 10.3390/s22041476.

[ZO18] Junqi Zhao und Esther Obonyo. „Towards a Data-Driven Approach to Injury Prevention in Construction“. In: *Advanced Computing Strategies for Engineering*. Series Title: Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018. DOI: 10.1007/978-3-319-91635-4_20.

[ZS12] Mi Zhang und Alexander A. Sawchuk. „USC-HAD: a daily activity dataset for ubiquitous activity recognition using wearable sensors“. In: *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*. Pittsburgh Pennsylvania: ACM, 2012. DOI: 10.1145/2370216.2370438.

[ZZL19] Wenting Zhang, Xiaohui Zhao und Zan Li. „A Comprehensive Study of Smartphone-Based Indoor Activity Recognition via Xgboost“. In: *IEEE Access* (2019). DOI: 10.1109/ACCESS.2019.2922974.

Anhang

A.1 Weitere Tabellen und Abbildungen zum DaRA-Datensatz

A.1.1 BPMN-Modellierungen von Teilprozessen

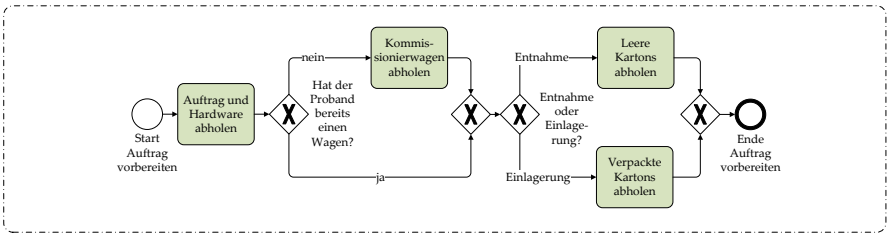


Abb. A.1 Idealisiertes BPMN des Teilprozesses *Auftrag vorbereiten* (KL114) mit dessen Feinprozessen

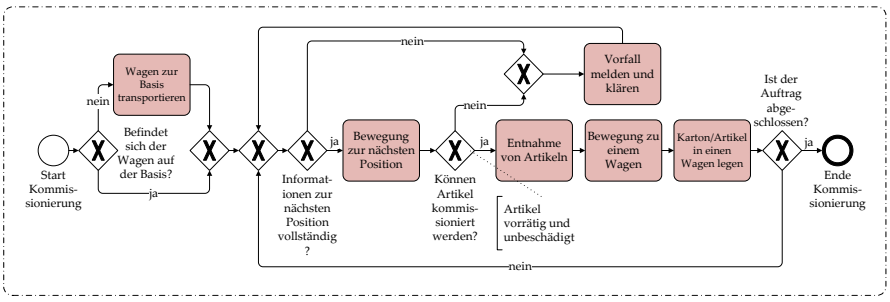


Abb. A.2 Idealisiertes BPMN der Teilprozesse *Kommissionierung – Wegzeit* (KL115) und *Kommissionierung – Greifzeit* (KL116) mit deren Feinprozessen

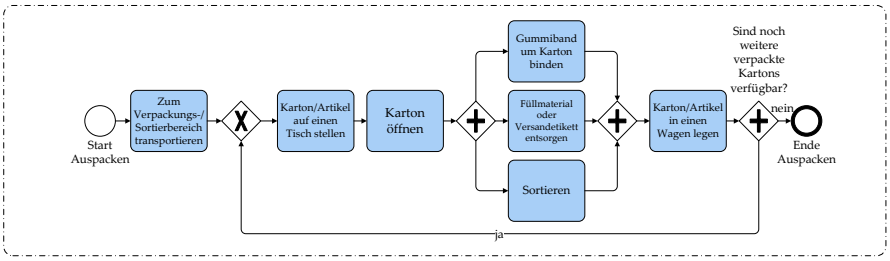


Abb. A.3 Idealisiertes BPMN des Teilprozesses *Auspacken* (KL117) mit dessen Feinprozessen

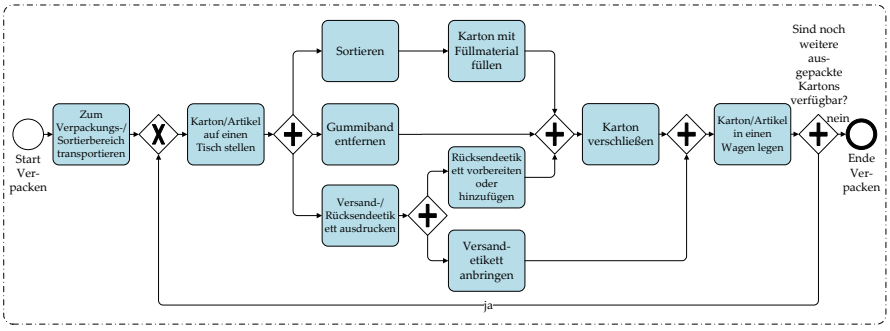


Abb. A.4 Idealisiertes BPMN des Teilprozesses *Verpacken* (KL118) mit dessen Feinprozessen

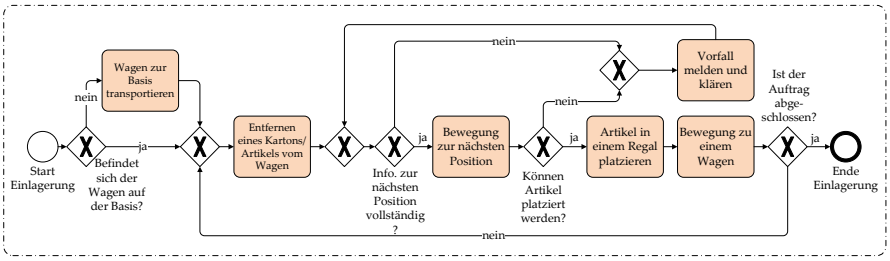


Abb. A.5 Idealisiertes BPMN der Teilprozesse *Einlagerung - Wegzeit* (KL119) und *Einlagerung - Greifzeit* (KL120) mit deren Feinprozessen

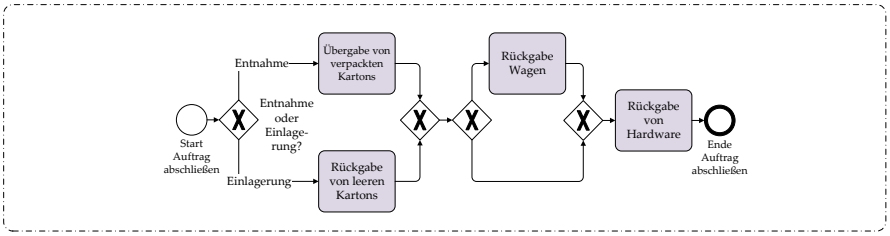


Abb. A.6 Idealisiertes BPMN des Teilprozesses *Auftrag abschließen* (KL121) mit dessen Feinprozessen

A.1.2 Taxonomien des DaRA-Datensatzes

Tabelle A.1 Einordnung des DaRA-Datensatzes (grün) in die Taxonomie von HAR-Datensätzen

Kategorie	Realisierungsoptionen	
HAR-Anwendungsbereiche	Gesundheitswesen / Rehabilitation	Bewegung und Sport
	Verkehr und Mobilität	Smart Homes und AAL
	Unterhaltung und Spiele	Verhaltensforschung / Psychologie
	Robotik/Mensch-Maschine-Interaktion	Industrie (Produktion / Logistik)
	Sicherheit und Überwachung	andere
Aufnahmeumgebungen	kontrollierte Umgebung	teilweise kontrollierte Umgebung
	reale Umgebung	
Szenarien	skriptbasiert	unter Alltagsbedingungen
	hybrid (Kombination: Skript und Alltag)	
Sensortypen	Trägheitssensoren	visuelle Sensoren
	physiologische/Biosensoren	akustische Sensoren
	Umgebungssensoren	Positionssensoren
	taktile Sensoren und Kraftsensoren	andere
Probanden-charakteristiken	Alter	Geschlecht
	Händigkeit	Körpergröße
	Körpermasse	aktivitätsbezogene Erfahrung
	berufliche Qualifikation	körperliche Beeinträchtigung
	Fitnesslevel	kultureller Hintergrund
	Sprache	andere

Tabellenfortsetzung

Kategorien	Realisierungsoptionen	
Label-Kategorien	Körperhaltungen / statische Aktivitäten	Fortbewegung
	Gesten / Feinmotorik-Aktivitäten	Mensch-Objekt-Interaktion
	Aktivitäten des täglichen Lebens	Sport
	zusammengesetzte Aktivitäten	Gesundheit
	Umwelt-/Verfahrenskontext	Verhalten
Label-Zeitstruktur	frameweise Annotation	segmentweise Annotation
	fensterweise Annotation	
Exklusivität von Labels	Einzel-Label	Mehrfach-Labels
Label-Hierarchie	flache Labels	hierarchische Labels
Label-Sicherheit / -Unsicherheit	harte Labels	probabilistische Labels
	mit Konfidenz annotierte Labels	
Automatisierungsgrad der Annotation	manuell	semi-automatisch
	vollautomatisiert	sensorfusionsbasiert
	durch Crowdsourcing	
Annotatoren-erfahrung	Experte des Anwendungsbereichs	geschulter interner Annotator
	Proband	Laie
Annotationsanzahl je Aufnahme	Einzelannotation durch einen Annotator	Mehrfachannotation durch mehrere Annotatoren
	Einzelannotation durch mehrere Annotatoren	
Revisionsmethoden	manuelle Prüfung	automatische Plausibilitätsprüfungen
	Vergleich mehrerer Annotationen	

Tabelle A.2 Einordnung des DaRA-Datensatzes (grün) in die Grundfunktionen des Informationsflusssystems der Kommissionierung. Die Auftragserfassung wurde in der Datenaufnahme nicht betrachtet.

Grundfunktion	Realisierungsmöglichkeiten			
Auftragserfassung	manuell	manuell, automatisch	automatisch	
Auftragsaufarbeitung	Einzelauftrag	Auftragsgruppen	Teilauftrag	
	keine	manuell	manuell, automatisch	automatisch
Weitergabe	ohne Beleg	mit Beleg		
	Einzelposition	mehrere Positionen		
Quittierung	je Entnahmeeinheit	je Position	alle Positionen	
	manuell	manuell, automatisch	automatisch	

Tabelle A.3 Einordnung des DaRA-Datensatzes (grün) in die Grundfunktionen des Materialflusssystems der Kommissionierung. Die Bereitstellung erfolgt dezentral und die Abgabe zentral.

Grundfunktion	Realisierungsmöglichkeiten			
Transport	keine Bewegung	Bewegung		
		manuell	mechanisiert	automatisiert
		1-dimensional	2-dimensional	3-dimensional
Bereitstellung/ Abgabe	statisch	dynamisch		
	zentral	dezentral		
	geordnet	teilgeordnet	ungeordnet	
Entnahme	manuell	mechanisiert	automatisiert	
	Einzelstückgut	Sammelstückgut		

Tabelle A.4 Einordnung des DaRA-Datensatzes (grün) in die Teilsysteme des Organisationssystems der Kommissionierung

Teilsystem	Realisierungsmöglichkeit		
Aufbauorganisation	einzonig	mehrzonig	
		Zonung durch Technik	Zonung durch Organisation
Ablauforganisation	einstufig	zweistufig	
	auftragsseriell	auftragsparallel	
	zonenseriell	zonenparallel	
Betriebsorganisation	ohne Optimierung	mit Optimierung	

A.1.3 Artikelstammdaten des Picking Labs

Tabelle A.5 Stammdaten der ein- und ausgelagerten Artikel

Lagerfach				Artikel						
ID	L	B	H	ID	Bezeichnung	Größe	Masse [g]	L	B	H
R1.1.6.A	95,5	39,5	21	4000090299	Selbstsicher.Mutter M5	S	1	0,7	0,7	0,4
R1.2.6.A	95,5	39,5	21	4000090302	Unterlegscheibe 5,3	S	0,4	1	0,1	0,1
R1.2.7.A	95,5	39,5	21	4000090290	Sechskant-Hutmutter M5	S	1,9	1	1,7	1,7
R1.3.5.A	95,5	39,5	21	4000090305	Schraube M4 Charge 6	S	1,2	0,8	0,8	0,8
R1.4.4.A	95,5	39,5	21	4000090291	Unterlegscheibe A8,4	S	1,6	1,5	1,5	0,1
R1.4.5.A	95,5	39,5	21	4000090296	Sicher.Mutter	S	1	0,7	0,7	0,5
R2.1.4.A	95,5	39,5	104	4000379340	Softshelljacke, Gr. S	M	680	29,7	21	5
R2.2.3.C	28,5	39,5	16	4000090155	Factory Xperts	M	102,2	20,5	27	5,5
R2.3.2.A	28,5	39,5	16	4000090190	Krawatte grau	M	71	19	7,5	2
R2.3.3.B	29	39,5	16	4000090229	Handschuhe blau, Gr. 8	M	100	30	16	10
R2.3.4.A	95,5	39,5	104	4000379341	Softshelljacke, Gr. M	M	700	29,7	21	5
R2.4.3.B	29	39,5	16	4000371276	Handschuhe gelb, Gr. 10	M	73	12	14,5	30
R3.1.4.A	95,5	39,5	104	4000090234	Weißer Hoodie, Gr. L	M	466	75	44	0,5
R3.4.3.A	28,5	39,5	16	4000090237	Tragebeutel grau	M	51	36	23	0,5
R3.4.3.B	29	39,5	16	4000090213	Weißes Poloshirt, Gr. M	M	24	25	19,3	2
R4.1.5.A	19	39,5	21	4000090215	Eiskratzer	S	14,1	10	10	0,2
R4.2.2.B	19	39,5	21	4000090263	Sechskant Mutter	S	14	2	2	0,5
R4.2.2.E	19	39,5	21	4000829177	Bit Sechskant 4 mm	S	5	0,7	2,5	0,7
R4.2.3.C	19	39,5	21	4000829107	Bit 6,5 mm Schlitz	S	4	0,7	2,5	0,7
R4.2.6.B	19	39,5	21	4000829115	Bit PH 3	S	6	0,7	2,5	0,7
R4.2.6.E	19	39,5	21	4000090242	Kugelschreiber PSI	S	16	14	1,5	1,5
R4.3.5.B	19	39,5	21	4000858991	Reißnadel	S	35,3	0,6	18,6	0,6
R4.4.4.E	19	39,5	21	4000090238	Drohne Rotor klein	S	3,4	6,5	5	0,5
R4.4.5.A	19	39,5	21	4000090208	CD-Driver	S	38	12,5	16	0,5
R4.4.5.D	19	39,5	21	4000829167	Bit T 27	S	6	0,7	2,5	0,7
R5.2.4.B	19	39,5	21	4000090222	Notizbuch A5 schwarz	M	324,5	21,5	15	1,7
R5.3.6.C	19	39,5	21	4000090297	Flat-Washer M6	S	0,3	1	1	0,1
R6.1.1.A	95,5	39,5	21	4000814335	Bügelsäge	L	820	26	84	3
R6.1.2.C	22	39,5	21	4000090245	Anti-Stress-Ball	M	28	6,5	6,5	6,5
R6.2.5.B	47,5	39,5	21	4000386550	Handwaschpaste	M	520	12	12	8
R6.3.1.A	95,5	39,5	21	4000090169	Drone Eachine	M	217,3	17,7	20	7,5
R6.3.8.A	95,5	39,5	21	4000090236	Briefablage	M	190,5	35	25	6,5
R6.4.4.C	32	39,5	21	4000090225	Notizheft A4 IML	M	428	30,3	21,5	0,7
R7.2.1.A	95,5	39,5	21	4000815504	Handbeil, 1000g	L	1.063	16,5	40,2	3,2
R7.2.2.A	95,5	39,5	21	4000090239	Fachtrenner Alu Silber	M	270,3	38,7	14,5	1,5
R7.3.1.A	95,5	39,5	21	4000090187	Palmenerde	L	5.149	32	21,8	14,8
R7.3.3.B	47,5	39,5	21	4000815503	Handbeil, 800g	L	803	14,7	38,2	2,9
R7.3.6.A	95,5	39,5	21	4000090179	Lichterkette Xmas	L	3.142	32	21,8	14,8
R8.2.2.A	95,5	39,5	41	4000815508	Handbeil, 1200g	L	1.290	18,5	41	2,5
R8.3.1.A	95,5	39,5	41	4000090292	Sportgetränk, Dose	M	330	5	5	13,5

Anmerkung: Artikelgröße ist in klein [S], mittel [M] und groß [L] unterteilt. *Artikelmaße* und *Lagerfach* sind in Länge [L], Breite [B] und Höhe [H] angegeben.

Die *Lagerfach-ID* (z. B. *R1.2.6.A*) gibt die Position des Artikels innerhalb des Regals an. Von links nach rechts gelesen bezeichnet *R1* den Regalkomplex 1, *2* das zweite Regal innerhalb dieses Komplexes, *6* die sechste Ebene von unten (Reihe) und *A* das erste Lagerfach von links (Spalte).

Artikelgröße wird nach Gewicht und Volumen kategorisiert:

- Klein [S]: Gewicht $\leq$ 50g UND Volumen $\leq$ 100cm^3
- Mittel [M]: Gewicht zwischen $>$ 50g und $\leq$ 800g UND/ODER Volumen zwischen $>$ 100cm^3 und $\leq$ 6.000cm^3
- Groß [L]: Gewicht $>$ 800g UND/ODER Volumen $>$ 6.000cm^3

A.1.4 Visuelle Dokumentation von Artikeln

Die Abbildungen A.7 bis A.14 zeigen die im Rahmen des DaRA-Datensatzes gepickten, verpackten, ausgepackten und eingelagerten Artikel. Die Artikel sind den acht *Fachbodenregalkomplexen* (R1 bis R8) zugeordnet, mit einer *Lagerfach-ID* (z. B. *R1.2.6.A*) sowie einer *Artikel-ID* (z. B. *4000090302*) gekennzeichnet und chronologisch nach den Lagerfach-IDs sortiert.



(a) R1.1.6.A, 4000090299



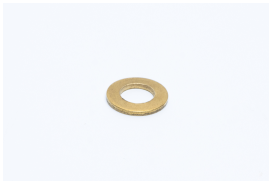
(b) R1.2.6.A, 4000090302



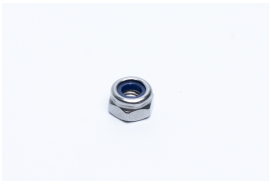
(c) R1.2.7.A, 4000090290



(d) R1.3.5.A, 4000090305



(e) R1.4.4.A, 4000090291



(f) R1.4.5.A, 4000090296

Abb. A.7 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 1, Gasse 1



(a) R2.1.4.A, 4000379340



(b) R2.2.3.C, 4000090155



(c) R2.3.2.A, 4000090190



(d) R2.3.3.B, 4000090229



(e) R2.3.4.A, 4000379341



(f) R2.4.3.B, 4000371276

Abb. A.8 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 2, Gasse 2



(a) R3.1.4.A, 4000090234



(b) R3.4.3.A, 4000090237



(c) R3.4.3.B, 4000090213

Abb. A.9 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 3, Gasse 2



(a) R4.1.5.A, 4000090215



(b) R4.2.2.B, 4000090263



(c) R4.2.2.E, 4000829177



(d) R4.2.3.C, 4000829107



(e) R4.2.6.B, 4000829115



(f) R4.2.6.E, 4000090242



(g) R4.3.5.B, 4000858991



(h) R4.4.4.E, 4000090238



(i) R4.4.5.A, 4000090208



(j) R4.4.5.D, 4000829167

Abb. A.10 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 4, Gasse 3



(a) R5.2.4.B, 4000090222



(b) R5.3.6.C, 4000090297

Abb. A.11 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 5, Gasse 3



(a) R6.1.1.A, 4000814335



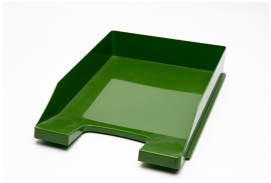
(b) R6.1.2.C, 4000090245



(c) R6.2.5.B, 4000386550



(d) R6.3.1.A, 4000090169



(e) R6.3.8.A, 4000090236



(f) R6.4.4.C, 4000090225

Abb. A.12 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 6, Gasse 4



(a) R7.2.1.A, 4000815504



(b) R7.2.2.A, 4000090239



(c) R7.3.1.A, 4000090187



(d) R7.3.3.B, 4000815503



(e) R7.3.6.A, 4000090179

Abb. A.13 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 7, Gasse 4



(a) R8.2.2.A, 4000815508



(b) R8.3.1.A, 4000090292

Abb. A.14 Visuelle Dokumentation der Artikel aus Fachbodenregalkomplex 8, Gasse 5

A.1.5 Kundenaufträge

Tabelle A.6 Kundenauftrag *2904*

Position	Lagerfach-ID	Artikel-ID	Artikelbezeichnung	Anzahl Einheiten
1	R1.2.7.A	4000090290	Sechskant-Hutmutter M5	20
2	R1.4.5.A	4000090296	Sicher.Mutter	10
3	R2.1.4.A	4000379340	Softshelljacke, Gr. S	1
4	R2.4.3.B	4000371276	Handschuhe gelb, Gr. 10	1
5	R3.1.4.A	4000090234	Weißer Hoodie, Gr. L	1
6	R3.4.3.A	4000090237	Tragebeutel grau	1
7	R4.1.5.A	4000090215	Eiskratzer	1
8	R4.2.2.B	4000090263	Sechskant Mutter	2
9	R4.3.5.B	4000858991	Reißnadel	3
10	R5.2.4.B	4000090222	Notizbuch A5 schwarz	1
11	R6.1.1.A	4000814335	Bügelsäge	1
12	R6.3.8.A	4000090236	Briefablage	1
13	R7.2.2.A	4000090239	Fachtrenner Alu Silber	1
14	R7.3.1.A	4000090187	Palmenerde	1
15	R8.3.1.A	4000090292	Sportgetränk, Dose	5

Tabelle A.7 Kundenauftrag *2905*

Position	Lagerfach-ID	Artikel-ID	Artikelbezeichnung	Anzahl Einheiten
1	R1.1.6.A	4000090299	Selbstsicher.Mutter M5	20
2	R1.4.4.A	4000090291	Unterlegscheibe A8,4	10
3	R2.2.3.C	4000090155	Factory Xperts	1
4	R2.3.4.A	4000379341	Softshelljacke, Gr. M	1
5	R3.1.4.A	4000090234	Weißer Hoodie, Gr. L	1
6	R3.4.3.B	4000090213	Weißes Poloshirt, Gr. M	1
7	R4.2.3.C	4000829107	Bit 6,5 mm Schlitz	2
8	R4.2.6.E	4000090242	Kugelschreiber PSI	3
9	R4.4.5.D	4000829167	Bit T 27	1
10	R5.3.6.C	4000090297	Flat-Washer M6	1
11	R6.1.2.C	4000090245	Anti-Stress-Ball	1
12	R6.2.5.B	4000386550	Handwaschpaste	1
13	R7.2.1.A	4000815504	Handbeil, 1000g	1
14	R7.3.6.A	4000090179	Lichterkette Xmas	1
15	R8.3.1.A	4000090292	Sportgetränk, Dose	3

Tabelle A.8 Kundenauftrag *2906*

Position	Lagerfach-ID	Artikel-ID	Artikelbezeichnung	Anzahl Einheiten
1	R1.2.6.A	4000090302	Unterlegscheibe 5,3	20
2	R1.3.5.A	4000090305	Schraube M4 Charge 6	10
3	R2.3.2.A	4000090190	Krawatte grau	1
4	R2.3.3.B	4000090229	Handschuhe blau, Gr. 8	1
5	R3.1.4.A	4000090234	Weißer Hoodie, Gr. L	1
6	R3.4.3.A	4000090237	Tragebeutel grau	1
7	R4.2.2.E	4000829177	Bit Sechskant 4 mm	2
8	R4.2.6.B	4000829115	Bit PH 3	3
9	R4.4.5.A	4000090208	CD-Driver	1
10	R5.2.4.B	4000090222	Notizbuch A5 schwarz	1
11	R6.3.1.A	4000090169	Drone Eachine	1
12	R6.4.4.C	4000090225	Notizheft A4 IML	1
13	R7.2.2.A	4000090239	Fachtrenner Alu Silber	3
14	R7.3.3.B	4000815503	Handbeil, 800g	1
15	R8.2.2.A	4000815508	Handbeil, 1200g	1

Tabelle A.9 Kundenauftrag *2904+2905*. Die Artikel der Positionen 12, 16 und 18 weichen vom ursprünglichen Auftrag *2905* (Positionen 6, 8 und 9 siehe Tabelle A.7) ab, sind jedoch im selben Regal gelagert.

Position	Lagerfach-ID	Artikel-ID	Artikelbezeichnung	Einheiten	Auftrag-ID
1	R1.1.6.A	4000090299	Selbstsicher.Mutter M5	20	2905
2	R1.2.7.A	4000090290	Sechskant-Hutmutter M5	20	2904
3	R1.4.4.A	4000090291	Unterlegscheibe A8,4	10	2905
4	R1.4.5.A	4000090296	Sicher.Mutter	10	2904
5	R2.1.4.A	4000379340	Softshelljacke, Gr. S	1	2904
6	R2.2.3.C	4000090155	Factory Xperts	1	2905
7	R2.3.4.A	4000379341	Softshelljacke, Gr. M	1	2905
8	R2.4.3.B	4000371276	Handschuhe gelb, Gr. 10	1	2904
9	R3.1.4.A	4000090234	Weißer Hoodie, Gr. L	1	2904
10	R3.1.4.A	4000090234	Weißer Hoodie, Gr. L	1	2905
11	R3.4.3.A	4000090237	Tragebeutel grau	1	2904
12	R3.4.3.A	4000090237	Tragebeutel grau	1	2905
13	R4.1.5.A	4000090215	Eiskratzer	1	2904
14	R4.2.2.B	4000090263	Sechskant Mutter	2	2904
15	R4.2.3.C	4000829107	Bit 6,5 mm Schlitz	2	2905
16	R4.2.6.B	4000829115	Bit PH 3	3	2905
17	R4.3.5.B	4000858991	Reißnadel	3	2904
18	R4.4.4.E	4000090238	Drohne Rotor klein	1	2905
19	R5.2.4.B	4000090222	Notizbuch A5 schwarz	1	2904
20	R5.3.6.C	4000090297	Flat-Washer M6	1	2905
21	R6.1.1.A	4000814335	Bügelsäge	1	2904
22	R6.1.2.C	4000090245	Anti-Stress-Ball	1	2905
23	R6.2.5.B	4000386550	Handwaschpaste	1	2905
24	R6.3.8.A	4000090236	Briefablage	1	2904
25	R7.2.1.A	4000815504	Handbeil, 1000g	1	2905
26	R7.2.2.A	4000090239	Fachtrenner Alu Silber	1	2904
27	R7.3.1.A	4000090187	Palmenerde	1	2904
28	R7.3.6.A	4000090179	Lichterkette Xmas	1	2905
29	R8.3.1.A	4000090292	Sportgetränk, Dose	3	2905
30	R8.3.1.A	4000090292	Sportgetränk, Dose	5	2904

A.1.6 Zeitlicher Ablauf der Szenarien je Proband

Tabelle A.10 Szenarienreihenfolge für jeden Probanden

ID	Aufnahmesession	1	2	3	4	5	6
P01	1	Szenario 2	Szenario 1	Szenario 3	Szenario 6	Szenario 7	Szenario 8
P02	1	Szenario 1	Szenario 3	Szenario 2	Szenario 5	-	-
P03	1	Szenario 3	Szenario 1	Szenario 2	Szenario 4	-	-
P04	2	Szenario 3	Szenario 1	Szenario 2	Szenario 5	Szenario 7	Szenario 8
P05	2	Szenario 1	Szenario 2	Szenario 3	Szenario 6	-	-
P06	2	Szenario 2	Szenario 1	Szenario 3	Szenario 4	-	-
P07	3	Szenario 1	Szenario 3	Szenario 2	Szenario 5	-	-
P08	3	Szenario 2	Szenario 1	Szenario 3	Szenario 6	-	-
P09	3	Szenario 3	Szenario 1	Szenario 2	Szenario 4	Szenario 7	Szenario 8
P10	4	Szenario 1	Szenario 2	Szenario 3	Szenario 6	-	-
P11	4	Szenario 2	Szenario 1	Szenario 4	-	-	-
P12	4	Szenario 3	Szenario 1	Szenario 2	Szenario 5	-	-
P13	5	Szenario 1	Szenario 2	Szenario 3	Szenario 6	-	-
P14	5	Szenario 2	Szenario 1	Szenario 3	Szenario 4	Szenario 7	Szenario 8
P15	5	Szenario 3	Szenario 1	Szenario 2	Szenario 5	-	-
P16	6	Szenario 1	Szenario 2	Szenario 3	Szenario 6	-	-
P17	6	Szenario 2	Szenario 1	Szenario 3	Szenario 4	-	-
P18	6	Szenario 3	Szenario 1	Szenario 2	Szenario 5	-	-

Tabelle A.11 Start- und End-Frames der Szenarien für jeden Probanden

ID	Szenario 1		Szenario 2		Szenario 3		Szenario 4		Szenario 5		Szenario 6		Szenario 7		Szenario 8	
	Start	Ende	Start	Ende	Start	Ende	Start	Ende	Start	Ende	Start	Ende	Start	Ende	Start	Ende
P01	42982	76096	2282	42981	76097	116696	-	-	-	-	116697	145289	145290	189631	189632	217906
P02	2282	38183	83218	132586	38184	83217	-	-	132587	175613	-	-	-	-	-	-
P03	19817	65374	65375	111696	2281	19816	111697	160368	-	-	-	-	-	-	-	-
P04	41459	78201	78202	111751	2505	41458	-	-	111752	169795	-	-	169796	217536	217537	244552
P05	2505	52671	52672	89760	89761	130517	-	-	-	-	130518	178361	-	-	-	-
P06	33376	73574	2505	33375	73575	105127	105128	150896	-	-	-	-	-	-	-	-
P07	1456	51406	86354	132808	51407	86353	-	-	132809	182078	-	-	-	-	-	-
P08	42536	78096	1456	42535	78097	107171	-	-	-	-	107172	145805	-	-	-	-
P09	34507	67405	67406	97351	1456	34506	97352	149106	-	-	-	-	149107	196388	196389	225074
P10	3268	49436	49437	94818	94819	138897	-	-	-	-	138898	198988	-	-	-	-
P11	66077	102192	3268	66076	-	-	102193	166748	-	-	-	-	-	-	-	-
P12	56250	109226	109227	157458	3268	56249	-	-	157459	216606	-	-	-	-	-	-
P13	1022	43366	43367	78275	78276	114953	-	-	-	-	114954	159088	-	-	-	-
P14	30691	55154	1022	30690	55155	83856	83857	153747	-	-	-	-	153748	243437	243438	278643
P15	53511	103704	103705	150217	1022	53510	-	-	150218	206646	-	-	-	-	-	-
P16	1855	49783	49784	83480	83481	137252	-	-	-	-	137253	174832	-	-	-	-
P17	37925	71865	1855	37924	71866	100173	100174	144427	-	-	-	-	-	-	-	-
P18	42661	78672	78673	131694	1855	42660	-	-	131695	204152	-	-	-	-	-	-

A.1.7 Explorative Anwendungen des DaRA-Datensatzes

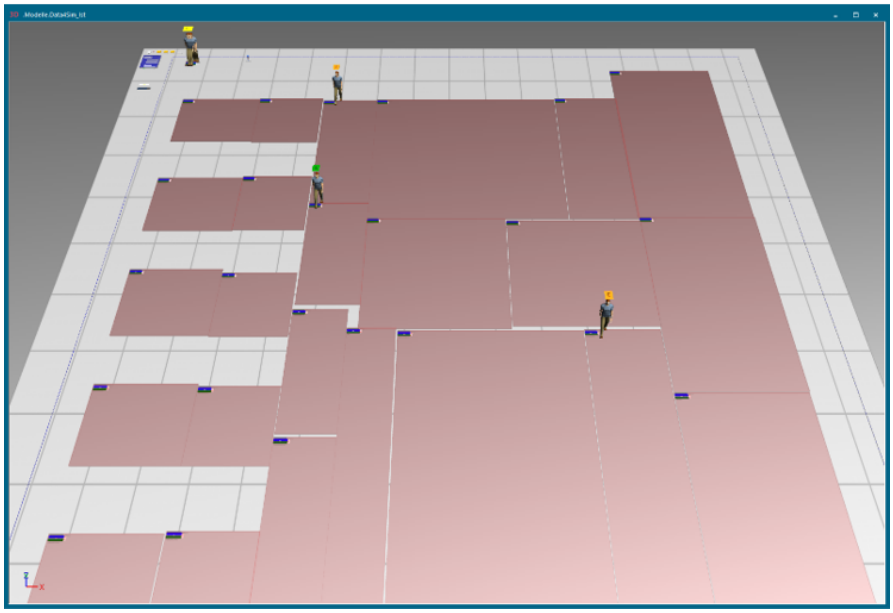


Abb. A.15 Exemplarische Visualisierung eines Simulationslaufs basierend auf Session 1 des DaRA-Datensatzes (entwickelt von der SimulationsDienstleistungsZentrum GmbH). Dargestellt sind die Zonen des Versuchsaufbaus im Picking Lab in Draufsicht sowie die Positionen von drei Probanden.

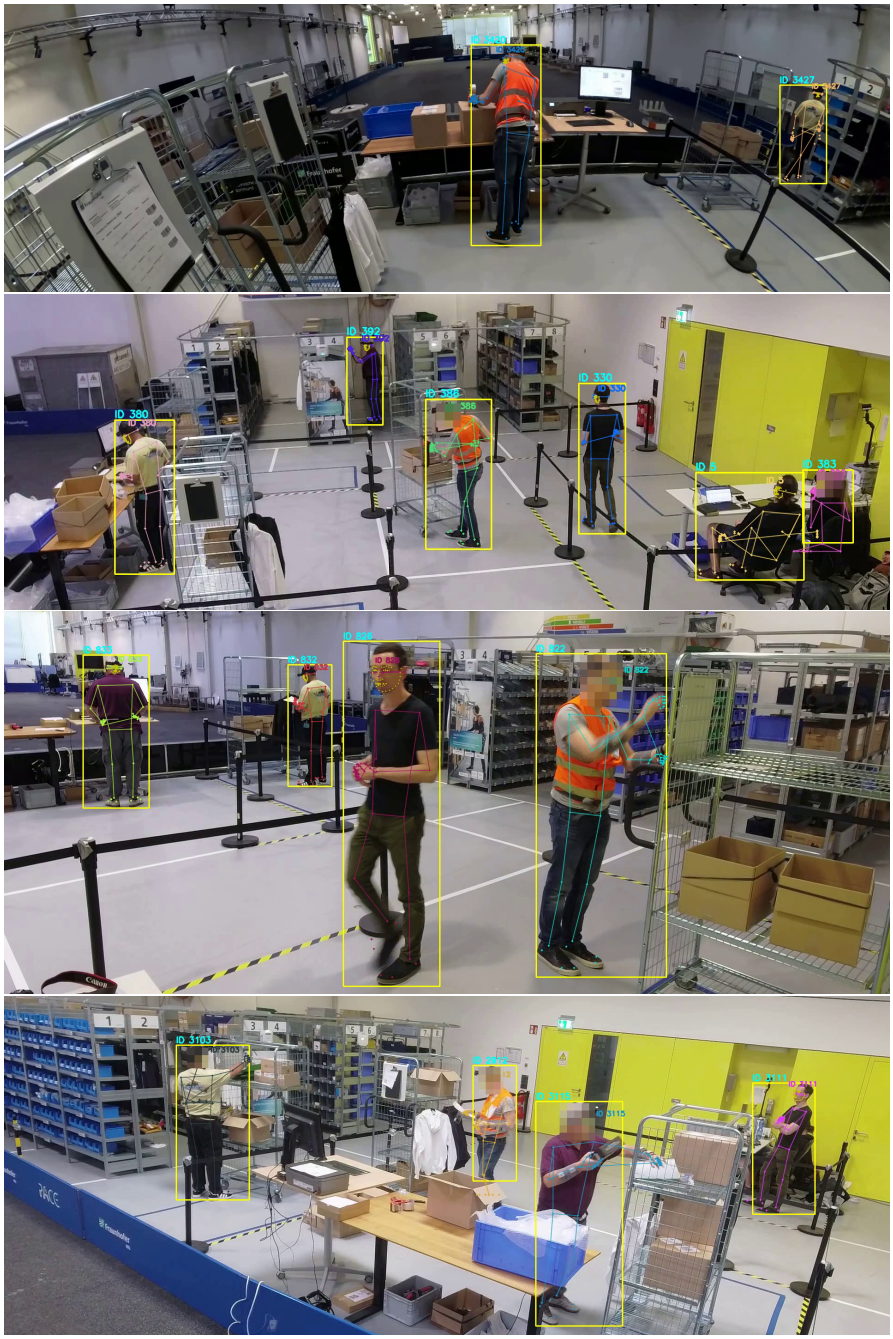


Abb. A.16 Exemplarische Visualisierungen automatisch extrahierter menschlicher Skelette aus Videodaten. Die vier Unterabbildungen zeigen unterschiedliche Kameraperspektiven zu verschiedenen Zeitpunkten in Session 2 des DaRA-Datensatzes.

A.2 Vorveröffentlichungen

Teile der Ergebnisse dieser Arbeit wurden durch den Autor bereits im Vorfeld veröffentlicht. Die Vorveröffentlichungen sind innerhalb der Arbeit referenziert und in das allgemeine Literaturverzeichnis integriert. Die Vorveröffentlichungen sind im Folgenden nach Rubriken unterteilt und chronologisch absteigend nach Erscheinungsdatum aufgeführt:

Bücher

- Christopher Reining und Friedrich Niemann. *Order Picking - Systems, Strategies, and Technologies for Efficient Material Flow Systems*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-73391-2
- Christopher Reining und Friedrich Niemann. *Kommissionierung - Systeme, Strategien und Technologien für effiziente Materialflusssysteme*. Hrsg. von Alice Kirchheim und Michael ten Hompel. Intralogistik. Status: eingereicht. Dortmund: Springer, 2026. ISBN: 978-3-662-70190-4

Journalbeiträge

- Friedrich Niemann u. a. „DaRA Dataset: Combining Wearable Sensors, Location Tracking, and Process Knowledge for Enhanced Human Activity and Human Context Recognition in Warehousing“. In: *Sensors* (2026). DOI: 10.3390/s26020739
- Friedrich Niemann u. a. „Context-Aware Human Activity Recognition in Industrial Processes“. In: *Sensors* (2021). DOI: 10.3390/s22010134
- Friedrich Niemann u. a. „LARa: Creating a Dataset for Human Activity Recognition in Logistics Using Semantic Attributes“. In: *Sensors* (2020). DOI: 10.3390/s20154083
- Christopher Reining u. a. „Human Activity Recognition for Production and Logistics—A Systematic Literature Review“. In: *Information* (2019). DOI: 10.3390/info10080245

Datensätze

- Friedrich Niemann u. a. *Data Fusion for advanced Research in industrial Applications (DaRA) – A Multi-Sensor, Multi-Level Annotated Dataset for Human Activity and Human Context Recognition in Warehousing*. 2026. DOI: 10.5281/ZENODO.10468175
- Friedrich Niemann u. a. *Test Annotations for Quality Evaluation of the DaRA Dataset – Annotated and Revised Video Data with Activity and Context Labels*. 2026. DOI: 10.5281/ZENODO.15118021
- Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 03) – A Motion Capture and Inertial Measurement Dataset*. 2023. DOI: 10.5281/ZENODO.8189341
- Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 02) – A Motion Capture and Inertial Measurement Dataset*. 2022. DOI: 10.5281/ZENODO.5761276
- Friedrich Niemann u. a. *Context-Aware Activity Recognition in Logistics (CAARL) – A optical marker-based Motion Capture Dataset*. 2021. DOI: 10.5281/ZENODO.5680951
- Friedrich Niemann u. a. *Logistic Activity Recognition Challenge (LARa Version 01) – A Motion Capture and Inertial Measurement Dataset*. 2020. DOI: 10.5281/ZENODO.3862782

Konferenzbeiträge

- Fernando Moya Rueda u. a. „Activity- and Context-Sensitive Recognition of Human-Centered Processes in Warehousing“. In: *European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2026)*. Status: eingereicht. Italien, 2026
- Friedrich Niemann u. a. „Towards Standardized Dataset Creation for Human Activity Recognition: Framework, Taxonomy, Checklist, and Best Practices“. In: *Annotation of Real-World Data for Artificial Intelligence Systems*. Springer Nature Switzerland, 2026. DOI: 10.1007/978-3-032-09117-8_5
- Luisa Elke u. a. „Bewegungsdaten als Planungsgrundlage“. In: *Logistics Journal: Proceedings* (2024). Publisher: Logistics Journal: Proceedings. DOI: 10.2195/LJ_PROC_ELKE_DE_202410_01
- Christopher Reining u. a. „A Tutorial on Dataset Creation for Sensor-based Human Activity Recognition“. In: *2023 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*. IEEE, 2023. DOI: 10.1109/PerComWorkshops56833.2023.10150401
- Friedrich Niemann u. a. „Applications of human activity recognition in industrial processes – Synergy of human and technology“. In: (2022). DOI: 10.48550/ARXIV.2212.02266
- Hülya Avsar u. a. „Cyber-physischer Zwilling Framework zur Generierung menschlicher Bewegungsdaten in der Intralogistik“. In: (2021). DOI: 10.2195/LJ_PROC_AVSAR_DE_202112_01
- Christopher Reining u. a. „Annotation Performance for multi-channel time series HAR Dataset in Logistics“. In: *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*. Austin, TX, USA: IEEE, 2020. DOI: 10.1109/PerComWorkshops48775.2020.9156170

Buchbeitrag

- Katja Ickstadt u. a. „Lernverfahren der Künstlichen Intelligenz zur Inwertsetzung von Daten: Automatisierte Erkennung und Prognose“. In: *Silicon Economy*. Hrsg. von Michael ten Hompel, Michael Henke und Boris Otto. Berlin, Heidelberg: Springer Berlin Heidelberg, 2022. DOI: 10.1007/978-3-662-63956-6_11

Software

- Kamil Seval u. a. *Tool for calculation of Order Picking Systems (Version 2)*. 2026. DOI: 10.5281/ZENODO.17961327
- Kamil Seval und Friedrich Niemann. *Tool for calculation of Order-Picking Systems*. 2024. DOI: 10.5281/ZENODO.14163472

Alle Publikationen wurden gemäß der Promotionsordnung als Vorveröffentlichung vom Autor in Absprache mit der Erstgutachterin bei der Fakultät Maschinenbau der Technischen Universität Dortmund angezeigt.

A.3 Forschungsprojekte

Die vorliegende Arbeit und die Vorveröffentlichungen (siehe Abschnitt A.2) geschahen im Rahmen folgender Forschungsprojekte, an denen der Autor mitgewirkt hat:

- Datengetriebene Simulation manueller Prozesse in der Logistik (Data4Sim) – Entwicklung einer kontextsensitiven Aktivitätserkennung für die Bereitstellung von Kontextdaten für die probabilistische Datenverarbeitungskette (gefördert von dem Bundesministerium für Wirtschaft und Energie auf der Grundlage eines Beschlusses des Deutschen Bundestages, Geschäftszeichen KK5072230MA3)
- Transfer Learning zur Aktivitätserkennung in der Intralogistik (gefördert von der Deutschen Forschungsgemeinschaft, Geschäftszeichen HO2403/14-2)
- Verbundprojekt: Innovationslabor Hybride Dienstleistung in der Logistik – Innovationslabor am Standort Dortmund zur Stärkung der logistischen Dienstleistung in Deutschland (LIDO); Teilprojekt: Grundlagenforschung zu Logistiksystemen und Arbeitsgestaltung (gefördert vom Bundesministerium für Bildung und Forschung, Förderkennzeichen 02P16Z201)
- Adaptive, ortsabhängige Aktivitätserkennung und Bewegungsklassifikation zur Analyse des manuellen Kommissionierprozesses (gefördert von der Deutschen Forschungsgemeinschaft, Geschäftszeichen HO2403/14-1)

A.4 Ethikvotum und Probandeneinwilligung

Erklärung der Ethikkommission: Die Erstellung des DaRA-Datensatzes erfolgte im Rahmen einer von der Ethikkommission der Fakultäten 9, 11–17 der Technischen Universität Dortmund (GEKTUDO2024-02, 15.04.2024) genehmigten Studie.

Probandeninformation und -einwilligungserklärung: Alle am DaRA-Datensatz beteiligten Probanden wurden mehrere Tage vor der Datenaufnahme durch eine von der oben genannten Ethikkommission geprüfte Probandeninformation über die Studie und die Datenschutzerklärung aufgeklärt. Nach Aufklärung und der Möglichkeit zum Gespräch mit dem Studienleiter über die Durchführung der Studie erklärten die Probanden ihre Einwilligung zur Studienteilnahme. Die Probanden haben ihre schriftliche Einwilligung zur Veröffentlichung pseudonymisierter personenbezogener Daten sowie pseudonymisierter Foto- und Videoaufnahmen und Bewegungsdaten aus inertialen Messeinheiten und Bluetooth-Low-Energy-Geräten in wissenschaftlichen Publikationen, Vorträgen und Datenbanken erteilt. Eine Vorlage der *Probandeninformation und -einwilligungserklärung* ist der Tabelle A.12 zu entnehmen.

Tabelle A.12 Dokumentvorlage der Probandeninformation und -einwilligungserklärung

Probandeninformation und -einwilligung
zur Durchführung einer Studie über manuelle Tätigkeiten in der Intralogistik

Datengetriebene Simulation manueller Prozesse in der Logistik (Data4Sim)
Förderkennzeichen: KK5072208AA3

Sehr geehrte an der Studienteilnahme interessierte Person,

wir möchten Sie fragen, ob Sie bereit sind, an der von uns vorgesehenen Studie teilzunehmen. Bevor Sie in die Teilnahme einwilligen, bitten wir Sie, die nachfolgenden Informationen aufmerksam zu lesen. Die Studie, die wir Ihnen hier vorstellen, wurde von der zuständigen Ethikkommission zustimmend bewertet (GEKTUDO2024-02) und vom zuständigen Projektträger genehmigt.

Für unser Projekt ist die Datenaufnahme von Bewegungsmustern manueller Tätigkeiten in der Intralogistik notwendig, um Erkenntnisse für automatische Bewegungsanalysen zu gewinnen oder zu erweitern. Unsere Forschung widmen wir den Methoden der Simulation und den Methoden der automatischen Aktivitätserkennung in industriellen Prozessen, wie sie im Freizeitbereich z. B. von Fitness-Trackern bereits bekannt sind. Dabei interessiert uns vor allem, wie sich die Bewegungsmuster verschiedener Menschen voneinander unterscheiden und ob es möglich ist, Bewegungsmuster sowie Prozess- und Positionsdaten automatisch in eine Simulation zu überführen.

Die Studie deckt die Datenaufnahme für die Methodenentwicklung für unser Projekt ab. Das Projekt wird im Rahmen des Zentralen Innovationsprogramms Mittelstand gefördert, einem Förderprogramm des Bundesministeriums für Wirtschaft und Klimaschutz. Neben dem Lehrstuhl für Förder- und Lagerwesen sind die folgenden Projektpartner involviert: MotionWiners© GmbH, SDZ Simulations Dienstleistungs Zentrum GmbH und Institute for Visual and Analytic Computing der Universität Rostock. Die Datenaufnahme wird im *Picking Lab* am Fraunhofer-Institut für Materialfluss und Logistik durchgeführt. Es sollen mehrere Personen daran teilnehmen. Die Studie wird veranlasst und organisiert durch den Studienleiter Friedrich Niemann. Finanziert wird die Studie durch den Projektträger.

Ihre Teilnahme an dieser Studie ist freiwillig. Sie werden in diese Aufnahmen also nur dann einbezogen, wenn Sie Ihre Einwilligung schriftlich erklären. Sofern Sie nicht an der Studie teilnehmen oder zu einem späteren Zeitpunkt nach bereits erfolgter Einwilligung aus ihr ausscheiden möchten, entstehen Ihnen daraus keine Nachteile.

Der Studienleiter hat Ihnen bereits eine Reihe von Informationen zu der geplanten Studie gegeben. Der nachfolgende Text soll Ihnen die Ziele und den Ablauf erläutern. Bevor wir jegliche Art von Daten von Ihnen erfassen, wird der Studienleiter ein Aufklärungsgespräch mit Ihnen führen. Bitte zögern Sie nicht, alle Punkte anzusprechen, die Ihnen unklar sind. Sie werden danach ausreichend Bedenkzeit erhalten, um über Ihre Teilnahme zu entscheiden.

Seite 1 von 11

Inhalt

Probandeninformation 3
1. Warum wird die Studie durchgeführt? 3
2. Wie ist der Ablauf der Studie und was muss ich bei der Teilnahme beachten? 3
3. Welche Risiken und Unannehmlichkeiten sind mit der Teilnahme an der Studie verbunden? .4
4. Wer darf an der Studie nicht teilnehmen? 4
5. Entstehen für mich Kosten durch die Teilnahme an der Studie? Erhalte ich eine Aufwandsentschädigung? 5
6. Bin ich während der Studie versichert? 5
7. Kann meine Teilnahme an der Studie vorzeitig beendet werden? 5
8. Was geschieht mit meinen Daten? 5
9. Welche gesetzlichen Rechte habe ich in Bezug auf meine Daten? 6
10. An wen wende ich mich bei weiteren Fragen? 6

Einwilligungserklärung 8

Probandeninformation

1. Warum wird die Studie durchgeführt?

Klassifikatoren zur automatischen Erkennung menschlicher Aktivitäten verarbeiten Signale verschiedener Sensorsysteme, z. B. Videos, Bluetooth oder köpergetragener Sensoren, die Beschleunigungsdaten aufnehmen. Auf diese Weise lassen sich Häufigkeit und Dauer verschiedener Aktivitäten wie Stehen, Laufen, Artikelhandhabung, etc. automatisch bestimmen und auswerten. Die auf diese Weise gewonnenen Informationen können zur zielgerichteten Verbesserung von Strukturen und Prozessen, an denen Menschen beteiligt sind, genutzt werden. Solche Ansätze werden in der industriellen Praxis bereits erfolgreich angewandt, zum Beispiel von der MotionMiners© GmbH aus Dortmund. Die hier beschriebene Studie widmet sich der Verbesserung der zugrundeliegenden Klassifikatoren und der Anreicherung der Datensätze, die zu ihrer Erstellung und ihrem Training verwendet werden. Weiterhin werden die klassifizierten Daten für Simulationen manueller Prozesse im Lager verwendet.

Methoden der menschlichen Aktivitätserkennung müssen mit heterogenen Populationen in den Trainings- und Testdaten zurechtkommen, denn die körperlichen Merkmale von Individuen beeinflussen ihr Bewegungsverhalten. Diesen Umstand berücksichtigt der Stand der Forschung zur Datensatzerstellung für menschliche Aktivitätserkennung unzureichend. In dem Projekt, in dessen Kontext diese Studie durchgeführt wird, werden Methoden zur Verknüpfung von realen Sensordaten mit Simulationsmodellen entwickelt. Die für die Experimente im Rahmen der Methodenentwicklung notwendige Datenbasis manueller Tätigkeiten in Industrieszenarien wird in einer Laborumgebung geschaffen. Um die Zielerreichung der Forschungsarbeit empirisch zu evaluieren, sind Menschen mit unterschiedlichen körperlichen Merkmalen als Versuchspersonen zu berücksichtigen.

2. Wie ist der Ablauf der Studie und was muss ich bei der Teilnahme beachten?

Die Gesamtdauer der Teilnahme beträgt ca. drei Stunden. Am Aufnahmetag besteht zunächst die Möglichkeit, mit dem Studienleiter alle offenen Fragen zu klären. Anschließend wird Ihnen das industrielle Szenario und Ihre Rolle darin erklärt. Sie erhalten Aufgaben, welche Tätigkeiten Sie zu erledigen haben, z. B. Artikel kommissionieren oder verpacken. Die Kommissionierung wird durch Listen, einem Pick-by-Light-System und einem Handterminal unterstützt. Bei einem Pick-by-Light-System werden Ihnen die zu greifenden Artikel über eine direkt am Entnahmefach angeordnete Fachanzeige übermittelt. Vorkenntnisse im Bereich logistischer bzw. industrieller Prozesse sind nicht notwendig.

Vor der Aufnahme werden physische Charakteristika von Ihnen erfasst. Mehr Informationen dazu finden Sie unten in der Datenschutzerklärung. Sie erhalten eine Einweisung zu allen Prozessschritten und lernen in Probedurchläufen die Verwendung der Kommissionierliste, des Pick-by-Light-Systems und des Handterminals kennen. Anschließend beginnen die Aufnahmen. Insgesamt nehmen wir ca. eine Stunde Datenmaterial auf.

3. Welche Risiken und Unannehmlichkeiten sind mit der Teilnahme an der Studie verbunden?

In der Studie werden alle Arbeitsschutzrichtlinien eingehalten. Die Bewegungen, welche Sie im Rahmen der Aufnahmen durchführen, entsprechen den Tätigkeiten in einem realen Lager: Sie werden Objekte von max. 13 kg greifen, handhaben, tragen und platzieren. Die Objekte werden nur für kurze Zeiträume getragen, z. B. 10 m von einem Regal zu einem Tisch. Es findet somit keine permanente Belastung statt. Außerdem findet keine Belastung über Ihre individuelle Belastungsgrenze hinaus statt, da Sie selber entscheiden, auf welche Weise Sie welche Aufgabe angehen. Sie können jederzeit Pausen einlegen.

Ihre Bewegungen werden mittels inertialen Messeinheiten (Beschleunigungssensoren und Drehratensensoren), stationären (sogenannte third-person view) und dynamischen (sogenannte egocentric vision / first-person view) Videokameras sowie Ihre Positionsdaten mittels Beacons (Sender bzw. Empfänger, die auf der Bluetooth Low Energy basieren) erfasst. Alle Sensortechnologien sind für den Menschen absolut ungefährlich, auch bei mehrstündiger Verwendung.

Es kann sein, dass Sie mit anderen Probanden gleichzeitig aufgezeichnet werden. Um die Probanden einfacher voneinander zu unterscheiden, bittet der Studienleiter Sie, ein einfarbiges Oberteil zu tragen (z. B. ein Proband trägt ein rotes T-Shirt, eine weitere Probandin ein weißes T-Shirt und ein dritter Proband ein blaues T-Shirt).

Weiterhin ist es notwendig Angaben zu Ihrem Alter, Geschlecht, Ihrer Körpergröße, Körpermasse [kg], Schuhgröße, Händigkeit, Ihren physischen Einschränkungen, Ihrer Vorerfahrung in der Kommissionierung, in der Verpackung und ähnlichen Studien sowie zu Ihrem Bildungsabschluss und Ihrer Berufsbezeichnung zu erheben. Zu den physischen Einschränkungen zählen Einschränkungen, die Ihre Bewegung beeinflussen könnten, aber dennoch das Greifen und Handhaben von Objekten bis zu 13 kg oder das Stehen und Gehen über einen Zeitraum von mindestens einer Stunde zulassen. Ein Beispiel einer solchen physischen Einschränkung wäre ein „Knorpelschaden zweiten Grades des rechten Knies“, welcher den Gang möglicherweise beeinflusst, aber das physische Arbeiten wie Stehen, Gehen und das Tragen von Artikeln zulässt und keine Schmerzen verursacht.

4. Wer darf an der Studie nicht teilnehmen?

Sie können an dieser Studie nur teilnehmen, wenn Sie keine Vorerkrankungen haben, die Ihnen das Greifen und Handhaben von Objekten bis zu 13 kg oder das Stehen und Gehen über einen Zeitraum von mindestens einer Stunde erschweren oder unmöglich machen. Wenn Sie eine der folgenden Vorerkrankungen haben, können Sie nicht an der Studie teilnehmen: Krebserkrankungen, chronische Lungenerkrankungen, chronische oder akute orthopädische Erkrankungen (z.B. bekannte Leiden an der Wirbelsäule), Einschränkungen aufgrund von Herz-Kreislauf-Erkrankungen (z. B. Herzschwächen, Herzklappenfehler, Herzrhythmusstörungen), Herzschrittmacher oder Erkältungssymptome. Bei Fragen

zu Vorerkrankungen wenden Sie sich bitte an den Studienleiter. Ausschließlich Personen im Alter zwischen 18 und 67 Jahren können an der Studie teilnehmen.

5. Entstehen für mich Kosten durch die Teilnahme an der Studie? Erhalte ich eine Aufwandsentschädigung?

Durch Ihre Teilnahme an dieser Studie entstehen Ihnen keine Kosten. Für Ihre Teilnahme an dieser Studie erhalten Sie keine Aufwandsentschädigung.

6. Bin ich während der Studie versichert?

Während der Aufnahmen im *Picking Lab* sind Sie nicht durch die TU Dortmund versichert. Wir weisen Sie ferner darauf hin, dass Sie auf dem Weg von und zum Studienort (dem *Picking Lab*) nicht unfallversichert sind.

7. Kann meine Teilnahme an der Studie vorzeitig beendet werden?

Die Teilnahme an der Datenaufnahme ist freiwillig. Sie können jederzeit, auch ohne Angabe von Gründen, Ihre Teilnahme beenden, ohne dass Ihnen dadurch irgendwelche Nachteile entstehen. Bei einer vorzeitigen Beendigung der Studie werden Ihre bis dahin erhobenen Daten gelöscht.

8. Was geschieht mit meinen Daten?

Während der Studie werden Fotos, Videos, Bewegungsdaten (mittels inertialer Messeinheiten) und Positionsdaten (mittels Beacons) erfasst und elektronisch gespeichert. Die für die Studie wichtigen Daten werden zusätzlich in pseudonymisierter und anonymisierter Form gespeichert, ausgewertet und gegebenenfalls weitergegeben. Eine pseudonymisierte und anonymisierte Weitergabe Ihrer Daten erfolgt im Rahmen von frei zugänglichen Datenbanken, wissenschaftlichen Beiträgen und von Präsentationen.

Pseudonymisiert bedeutet, dass keine Angaben von Namen oder Initialen verwendet werden, sondern nur ein Nummern- und/oder Buchstabencode. Anonymisiert bedeutet, dass Ihre Daten nicht mehr Ihrer Person zugeordnet werden können, indem Ihr Gesicht auf Fotos und Videos verpixelt und der Ton von Videos entfernt ist.

Die Daten sind gegen unbefugten Zugriff auf einem externen Speichermedium gesichert, auf das nur der Studienleiter Zugriff hat.

Einzelheiten entnehmen Sie bitte der Einwilligungserklärung, die im Anschluss an diese Probandeninformation abgedruckt ist.

Kontaktstelle

Es existiert außerdem eine Kontaktstelle am Lehrstuhl für Förder- und Lagerwesen. Teilnehmer können sich an diese Kontaktstelle wenden:

Technische Universität Dortmund
Lehrstuhl für Förder- und Lagerwesen
Joseph-von-Fraunhofer-Straße 2-4
44227 Dortmund

Sekretariat
Telefon: +49 231 755-2765 Fax: +49 231 755-4768
E-Mail: tanja.kiehne@tu-dortmund.de

9. Welche gesetzlichen Rechte habe ich in Bezug auf meine Daten?

Gemäß Art. 7 Abs. 3 DSGVO können Sie Ihre einmal erteilte Einwilligung jederzeit für die Zukunft widerrufen. Dies hat zur Folge, dass wir die Datenverarbeitung, die auf dieser Einwilligung beruhte, für die Zukunft nicht mehr fortführen dürfen.

Sie sind gemäß Art. 15 DSGVO jederzeit berechtigt, eine umfangreiche Auskunftserteilung zu den zu Ihrer Person gespeicherten Daten zu ersuchen.

Gemäß Art. 17 DSGVO können Sie jederzeit die Berichtigung, Löschung und Sperrung personenbezogener Daten verlangen.

Gemäß Art. 18 DSGVO können Sie die Einschränkung der Verarbeitung Ihrer personenbezogenen Daten verlangen.

Sie können darüber hinaus jederzeit ohne Angabe von Gründen von Ihrem Widerspruchsrecht Gebrauch machen und die erteilte Einwilligungserklärung mit Wirkung für die Zukunft abändern oder gänzlich widerrufen. Sie können den Widerruf entweder postalisch, per E-Mail oder per Fax formlos an den Vertragspartner übermitteln. Es entstehen Ihnen dabei keine anderen Kosten als die Portokosten bzw. die Übermittlungskosten nach den bestehenden Basistarifen.

Gemäß Art. 77 DSGVO können Sie sich bei einer Aufsichtsbehörde beschweren. In der Regel können Sie sich hierfür an die Aufsichtsbehörde Ihres üblichen Aufenthaltsortes oder Arbeitsplatzes oder unseres Geschäftssitzes wenden.

10. An wen wende ich mich bei weiteren Fragen?

Beratungsgespräche an der Prüfstelle

Sie haben stets die Gelegenheit zu weiteren Beratungsgesprächen mit dem Studienleiter.

Technische Universität Dortmund
Lehrstuhl für Förder- und Lagerwesen
Joseph-von-Fraunhofer-Straße 2-4
44227 Dortmund

Niemann, Friedrich
Telefon: +49 231 755-4548
E-Mail: friedrich.niemann@tu-dortmund.de

Datenschutzerklärung

Mir ist bekannt, dass bei dieser Studie personenbezogene Daten über mich erhoben, gespeichert und ausgewertet werden sollen. Die Verwendung dieser Angaben setzt vor der Teilnahme an der Studie folgende freiwillig abgegebene Einwilligungserklärung voraus, das heißt, ohne die nachfolgende Einwilligung kann ich nicht an der Studie teilnehmen.

1. Ich erkläre mich damit einverstanden, dass im Rahmen dieser Studie personenbezogene Daten, insbesondere Angaben über Alter, Geschlecht, Körpergröße, Körpermasse, Schuhgröße, Händigkeit, physische Einschränkungen, Vorerfahrung in der Kommissionierung, in der Verpackung und ähnlichen Studien sowie Bildungsabschluss und Berufsbezeichnung über mich erhoben und auf elektronischen Datenträgern am Lehrstuhl für Förder- und Lagerwesen aufgezeichnet werden. Soweit erforderlich, dürfen die erhobenen Daten pseudonymisiert veröffentlicht werden:

   a) in frei zugänglichen Datenbanken,

   b) in wissenschaftlichen Beiträgen,

   c) in Präsentationen.

   ☐ Ich erkläre mich mit Punkt 1 einverstanden.
   ☐ Ich erkläre mich mit Punkt 1 **nicht** einverstanden.

2. Außerdem erkläre ich mich damit einverstanden, dass im Rahmen dieser Studie Fotos und Videoaufnahmen von mir aufgezeichnet und meine Bewegungen mittels inertialen Messeinheiten (Beschleunigungssensoren und Drehratensensoren), stationären (third-person view) und dynamischen (sogenannte egocentric vision / first-person view) Videokameras sowie Positionsdaten mittels Beacons (Sender bzw. Empfänger, die auf der Bluetooth Low Energy basieren) erfasst und auf elektronischen Datenträgern am Lehrstuhl für Förder- und Lagerwesen gespeichert werden. Soweit erforderlich, dürfen die erstellten Fotos und Videos pseudonymisiert (verschlüsselt) und anonymisiert (Fotos mit verpixeltem Gesicht und Videos mit verpixeltem Gesicht und ohne Ton) und die Sensordaten pseudonymisiert (verschlüsselt) veröffentlicht werden:

   a) in frei zugänglichen Datenbanken,

   b) in wissenschaftlichen Beiträgen,

   c) in Präsentationen.

   Ich bin mir darüber im Klaren, dass die anonymisierten und verpixelten Fotos und Videos im Internet von beliebigen Personen abgerufen werden können.
   ☐ Ich erkläre mich mit Punkt 2 einverstanden.
   ☐ Ich erkläre mich mit Punkt 2 **nicht** einverstanden.

3. Die Einwilligung zur Erhebung und Verarbeitung meiner personenbezogenen Daten kann jederzeit widerrufen werden. Ich bin bereits darüber aufgeklärt worden, dass ich jederzeit die Teilnahme an

Datengetriebene Simulation manueller Prozesse in der Logistik (Data4Sim)
Förderkennzeichen: KK5072230MA3

Einwilligungserklärung

.....
Vorname und Name der Probandin / des Probanden in Druckbuchstaben

geb. am ..... Teilnehmer-Nr. (vom Studienleiter auszufüllen) .....

Ich bin in einem persönlichen Gespräch durch den Studienleiter

.....
Name des Studienleiters in Druckbuchstaben

ausführlich und verständlich über die Aufnahmen sowie über Wesen, Bedeutung, Risiken und Tragweite der Studie aufgeklärt worden. Ich habe darüber hinaus den Text der Probandeninformation sowie die hier nachfolgend abgedruckte Datenschutzerklärung gelesen und verstanden. Ich hatte die Gelegenheit, mit dem Studienleiter über die Durchführung der Studie zu sprechen. Alle meine Fragen wurden zufriedenstellend beantwortet.

Möglichkeit zur Dokumentation zusätzlicher Fragen seitens der Probandin / des Probanden oder sonstiger Aspekte des Aufklärungsgesprächs:

Ich hatte ausreichend Zeit, mich zu entscheiden.

Mir ist bekannt, dass ich jederzeit und ohne Angabe von Gründen meine Einwilligung zur Teilnahme an der Prüfung zurückziehen kann (mündlich oder schriftlich), ohne dass mir daraus Nachteile entstehen.

der Studie beenden kann. Im Fall eines solchen Widerrufs meiner Einwilligung, an der Studie teilzunehmen, werden die bis dahin erfassten Daten gelöscht.

☐ Ich erkläre mich mit Punkt 3 einverstanden.
☐ Ich erkläre mich mit Punkt 3 **nicht** einverstanden.

4. Ich erkläre mich damit einverstanden, dass meine Daten nach Beendigung der Studie zehn Jahre aufbewahrt werden. Danach werden meine personenbezogenen Daten gelöscht.
☐ Ich erkläre mich mit Punkt 4 einverstanden.
☐ Ich erkläre mich mit Punkt 4 **nicht** einverstanden.

Ich versichere hiermit, dass ich keine Vorerkrankungen habe, die es mir erschweren oder unmöglich machen, Gegenstände bis zu 13 kg zu greifen und zu handhaben oder über einen Zeitraum von mindestens einer Stunde zu stehen und zu gehen. Ich bestätige hiermit, dass mir zum Zeitpunkt der Studie keine Krebserkrankungen, chronische Lungenerkrankungen, chronische oder akute orthopädische Erkrankungen (z.B. bekannte Leiden an der Wirbelsäule), Einschränkungen aufgrund von Herz-Kreislauf-Erkrankungen (z. B. Herzschwächen, Herzklappenfehler, Herzrhythmusstörungen), Herzschrittmacher oder Erkältungssymptome bekannt sind.

.....
Name der Probandin / des Probanden in Druckbuchstaben

....
Datum Unterschrift der Probandin / des Probanden

Ich erkläre mich bereit,
an der oben genannten Studie
freiwillig teilzunehmen.

Ein Exemplar der Probandeninformation und -einwilligung habe ich erhalten. Ein Exemplar verbleibt am *Lehrstuhl für Förder- und Lagerwesen*.

.....
Name der Probandin / des Probanden in Druckbuchstaben

....
Datum Unterschrift der Probandin / des Probanden

Ich habe das Aufklärungsgespräch geführt und die Einwilligung der Probandin / des Probanden eingeholt.

.....
Name des Studienleiters in Druckbuchstaben

....
Datum Unterschrift des aufklärenden **Studienleiters**

A.5 An den Forschungsarbeiten beteiligte Personen und ihre Beiträge

An Teilen der Forschungsarbeiten, welche in diese Arbeit eingeflossen sind oder auf die sie Bezug nimmt, waren neben dem Autor dieser Arbeit weitere Personen im Rahmen der Forschungsprojekte (siehe Abschnitt A.3) beteiligt. Die Art ihrer Beiträge ist – nach der explorativen Studie CAARL in Tabelle A.13 sowie nach dem DaRA-Datensatz und der Prozesserkennung in Tabelle A.14 – unterteilt und in chronologisch aufsteigender Reihenfolge ihrer Durchführung dargestellt.

Tabelle A.13 An der explorativen Studie CAARL (siehe Abschnitt 4.1) beteiligte Personen und ihre Beiträge

Beitrag	Neben dem Autor beteiligte Personen
Erstellung des Annotationstools SARA	Erik Altermann, Philipp Oberdiek, Raphael Spiekermann
Visualisierung des CAARL-Logos in Abbildung 4.1	Markus Heinzelmann
Teilnahme an den Aufnahmen als Proband	Die Identitäten der beiden Probanden werden nicht veröffentlicht. Alle Probanden haben der Veröffentlichung der Aufnahmedaten zugestimmt.
Unterstützung bei der Vorbereitung der Versuchsumgebung sowie bei der Datenaufnahme	Hülya Bas, Nilah Ravi Nair, Janine Anika Steffens
Nachbearbeitung der Videos	Janine Anika Steffens
Manuelle Revision	Hülya Bas, Nilah Ravi Nair, Janine Anika Steffens
Implementierung von RF, QDA und XGBoost für die kontext-sensitive Aktivitätserkennung in Abschnitt 4.1.2	Stefan Lüdtke

Tabelle A.14 An dem DaRA-Datensatz (siehe Abschnitt 5.1) und der Prozesserkennung (siehe Abschnitt 6.3) beteiligte Personen und ihre Beiträge

Beitrag	Neben dem Autor beteiligte Personen
Visualisierung des DaRA-Logos in Abbildung 5.1	Markus Heinzelmann
Visualisierung der Klassenkategorien als Symbole in den Abbildungen 4.7 und 5.13 sowie der Tabelle 5.3	Markus Heinzelmann

Tabellenfortsetzung	
Beitrag	**Neben dem Autor beteiligte Personen**
Unterstützung bei der Planung der Datensatzerstellung	René Grzeszick, Veronika Kretschmer, Marie-Claire Olivier, Christopher Reining, Fernando Moya Rueda
Unterstützung bei der Vorbereitung der Versuchsumgebung	Eileen Bork, Ibrahim Elibueyuek, Luisa Elke, Michael Frichert, Kamil Seval, Marie-Claire Olivier, Alexander Orth, Fernando Moya Rueda, Linda Maria Wings, Kai Zurkuhl
Unterstützung bei der Datenaufnahme	Eileen Bork, Kai Zurkuhl
Bedienung der IMUs und Beacons	Alexander Orth, Fernando Moya Rueda
Teilnahme an den Aufnahmen als Proband	Die Identitäten der 18 Probanden werden nicht veröffentlicht. Alle Probanden haben der Veröffentlichung der Aufnahmedaten zugestimmt (siehe Tabelle A.12).
Nachbearbeitung der Videos	Eileen Bork, Michael Frichert
Manuelle Annotation und Revision	Ahmad Abdulaal, Hashem Almatalka, Hussam Asskar, Eileen Bork, Bhavadip Dobariya, Michael Frichert, Eya Ghroubi, Nilah Ravi Nair, Christopher Reining, Tobias Riedel, Fernando Moya Rueda, Dustin Schauten, Mutaz Abu Seer, Kamil Seval, Fabio Kersting, Fabian König, Syed Abdul Haseeb Qadri, Mohammad Youssef, Kai Zurkuhl
Erstellung der Fotos in den Abbildungen 2.6, 5.2, 5.4, 5.5 sowie A.7 bis A.14	Sebastian Beierle
Implementierung der TCNNs für die Aktivitätserkennung in Abschnitt 6.2.4	Fernando Moya Rueda
Implementierung der Transformer- und HMM-Modelle für die Prozesserkennung in Abschnitt 6.3	Fernando Moya Rueda
Implementierung der LSTM-Modelle für die Prozesserkennung in Abschnitt 6.3	Moh'd Khier Al Kfari

A.6 Erklärung zur Verwendung generativer KI-Systeme

Bei der Erstellung dieser Dissertation wurden generative KI-basierte Systeme eingesetzt. Die inhaltliche Verantwortung sowie die Auswahl, Bewertung und endgültige Fassung sämtlicher Inhalte liegen ausschließlich beim Verfasser dieser Arbeit. Die verwendeten KI-Systeme sowie deren jeweilige Einsatzbereiche sind in der nachfolgenden Tabelle aufgeführt.

Tabelle A.15 KI-Systeme im Rahmen der Arbeit

KI-System	Einsatzbereiche
ChatGPT	Sprachliche Überarbeitung von Textentwürfen Unterstützung bei der Strukturierung von Textpassagen Unterstützung bei der Pythonprogrammierung Unterstützung beim Brainstorming
DeepL	Übersetzung eigener englischsprachiger Textpassagen Sprachliche Überarbeitung von Textentwürfen
LanguageTool	Rechtschreib- und Grammatikkontrolle Sprachliche Überarbeitung von Textentwürfen
yolov11m-face	Pseudonymisierung durch automatische Verpixelung von Gesichtern in den Videoaufnahmen des DaRA-Datensatzes (siehe Abbildungen 5.6, 5.12 und 5.13)

A.7 Studentische Arbeiten im Rahmen der Forschungsarbeiten

Vom Autor betreute Arbeiten lieferten Eingaben, Vorarbeiten und Anregungen. Alle studentischen Arbeiten, die im Kontext der vorliegenden Ausarbeitung entstanden, sind im Folgenden chronologisch absteigend nach Abgabedatum aufgeführt.

Tabelle A.16 Studentische Arbeiten im Rahmen der Forschungsarbeiten

Datum	Titel	Typ	Name
13.05.2026	Referenzarchitektur für Agentic AI in der Intralogistik: Multi-Agent-Framework zur generativen Prozessanalyse von HAR-Daten mit LLM-Orchestrierung und REFA-Konformität	MA	Markus Phillip Fiur
04.05.2026	Explorative Datenanalyse zur Identifikation von Annotationsfehlern in Human Activity Recognition Daten – ein Beitrag zur Qualitätssteigerung und Aufwandsreduktion bei der Datensatzerstellung	MA	Noah Poincein
05.03.2026	Large Language Models zur Analyse von Industrieprozessen – Potenzial von Künstlicher Intelligenz für die Prozessoptimierung	BA	Mithursan Sinnathamby
13.01.2026	Development of a Robust Pipeline for Human Skeleton Generation from Multi-Perspective Camera Data in the DaRA Dataset	MA	Durga Shanmukha Sridatta Arun Hari Haranath
01.12.2025	Weiterentwicklung eines Python-basierten Softwaretools zur strategischen Grobplanung von Kommissioniersystemen	MA	Christian Bogler
27.10.2025	Datensätze zur menschlichen Aktivitätserkennung besser verstehen – Entwicklung eines Verfahrens des Data Storytellings mittels Programmierung	MA	Marten Florian Krix
13.10.2025	Entwicklung eines Leitfadens zur systematischen und vergleichbaren Evaluation von HAR-Datensätzen	BA	Fabio Fritz Kersting
28.07.2025	Forschungsdatenuntersuchung in der Logistik: Analyse und Visualisierung von Bewegungsdaten aus der Data4Sim-Studie	MA	Günay Ertürk
24.07.2025	Programmierung von dynamischen Datenvisualisierungen anhand der Industriedaten eines Kommissionierprozesses mit HTML, JavaScript und D3.js	MA	Simon Schöppner
30.05.2025	Entwicklung und Bewertung von Revisionsmethoden zur Steigerung der Qualität industrieller Datensätze	BA	Mutaz Majed Ahmad Awad Abu Seer

Tabellenfortsetzung

Datum	Titel	Typ	Name
10.09.2024	Entwicklung einer Lehrveranstaltung unter Einbeziehung von Motion-Mining® im Kontext der menschlichen Aktivitätserkennung in der Intralogistik	MA	Ibrahim Elibueyuek
24.05.2024	Entwicklung und Implementierung eines Softwaretools zur strategischen Grobplanung von Kommissioniersystemen	MA	Kamil Seval
28.11.2022	Framework zur kontextbasierten Aktivitätserkennung in der Intralogistik	MA	Anna Wäschenbach
07.08.2022	Systematische Literaturübersicht zur kontextbasierten Aktivitätserkennung	BA	Daniel Darmograj
28.02.2022	Entwicklung und Evaluierung eines Frameworks zur Erkennung von Kommissionieraktivitäten mittels Kontext	MA	Janik Hillebrecht
04.10.2021	Analyse von Sensordaten menschlicher Bewegungen in der Intralogistik	MA	Jan Belecke
30.08.2021	Aufstellung eines allgemeingültigen Kriterienkatalogs zur Bewertung von zeitwirtschaftlichen Methoden am Beispiel eines simulierten Intralogistikszenarios	MA	Tarik Akova
27.07.2021	Kontexterkennung – Systematische Übersicht und Analyse des Stands der Forschung	BA	Zahide Dündar
26.04.2021	Bestimmung von Einflussgrößen auf menschliche Bewegungen in innerbetrieblichen Materialflusssystemen	BA	Felix Kremer
15.03.2021	Kontexterkennung – Systematische Übersicht und Analyse des Stands von Wissenschaft und Technik	BA	Ezgi Cimsir
07.04.2019	Anwendungsfälle menschlicher Aktivitätserkennung – Systematische Übersicht des Stands von Wissenschaft und Technik	BA	Till Kahlert
28.02.2019	Anwendungsfälle menschlicher Aktivitätserkennung – Systematische Übersicht des Stands von Wissenschaft und Technik	PA	Timo Albers, Sebastian Faber, Daniel Kuper, Maren Radmacher, Patrick Schowtjak,

Anmerkung: MA = Masterarbeit, BA = Bachelorarbeit, PA = Projektarbeit