

# Entwicklung einer KI-Objekterkennung für technische Zeichnungen im Maschinenbau

Zur Erlangung des akademischen Grades eines

**Dr.-Ing.**

von der Fakultät Maschinenbau  
der Technischen Universität Dortmund  
genehmigte Dissertation

**Fabian Dillenhöfer, M.Sc.**

aus  
Dortmund

Tag der mündlichen Prüfung: 15. Dezember 2023

1. Gutachter: Prof. Dr.-Ing. habil. Bernd Künne
2. Gutachter: Prof. Dr.-Ing. Jens Bechthold

**Dortmund, 2023**

# Vorwort

Die vorliegende Arbeit wurde im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Fachgebiet Maschinenelemente der Technischen Universität Dortmund erstellt. Die Inhalte sind innerhalb des Digitalisierungsprojektes „TZ Digital.nrw“, welches durch die DH.NRW mit Mitteln des Ministeriums für Kultur und Wissenschaft (MKW) des Landes Nordrhein-Westfalen unter dem Förderkennzeichen 214-5.01.03.02 - 145504 finanziell unterstützt wurde, sowie während des Projektes „KI unterstütztes VR-Lernmedium für Maschinenelemente (AssistME)“ (Fördernummer: FRFMM-740/2022) gefördert durch die Stiftung Innovationen in der Hochschullehre (Finanzmittel aus dem Bund-Länder-Gremium), dessen Trägerschaft die gemeinnützigen Toepfer Stiftung gGmbH inne hat, entstanden.

An dieser Stelle möchte ich mich ganz besonders bei meinem Doktorvater Herrn Prof. Dr.-Ing. habil. Bernd Künne für die hervorragende fachliche und persönliche Betreuung und das Vertrauen während der Beschäftigung bedanken. Darüber hinaus bedanke ich mich recht herzlich bei Herrn Prof. Dr.-Ing. Jens Bechthold für die Arbeit als Zweitgutachter und die Zusammenarbeit im Projekt TZ Digital.nrw. Zuletzt spreche ich Herrn Prof. Dr.-Ing. Ralph Sievering und Herrn Prof. Dr.-Ing. Dipl.-Inform. Andreas Zabel meinen persönlichen Dank für die faire und nette Behandlung im Rahmen des gesamten Prüfungsverfahrens aus.

Zudem möchte ich bei allen am Fachgebiet Maschinenelemente während meiner Promotion tätigen Personen für die sehr gute und erfolgreiche Zusammenarbeit danken, sodass ich mich nicht nur fachlich, sondern auch persönlich weiterentwickeln konnte. Mein Dank gilt insbesondere Dr. Jan Knipschild, Abdullah Doksanbir, Lennart Kraske und Frau Dr. Ulrike Willms für die Unterstützung, die erkenntnisreichen fachlichen Diskussionen und die Zusammenarbeit in Projekten und bei diversen Aufgaben. Ich habe mich am Fachgebiet Maschinenelemente stets wohl gefühlt und konnte unter sehr guten Arbeitsbedingungen trotz der global schwierigen Zeiten wachsen.

Schlussendlich bedanke ich mich bei meinen Eltern Carmen und Ulrich, die mir diesen Lebensweg ermöglicht und mich stets unterstützt haben. Außerdem standen mein Bruder Timo und die Freunde immer motivierend zur Seite.

Dortmund, Dezember 2023

Fabian Dillenhöfer

# Kurzfassung

Das Ziel der Arbeit ist eine Machbarkeitsstudie einer KI-gestützten Objekterkennung von Bauteilen in technischen Zeichnungen des Maschinenbaus. Anschließend soll das KI-Niveau mit dem eines Studierenden verglichen werden. Zuletzt sollen Anwendungsszenarien wie z.B. in der Lehre für die KI verifiziert werden.

Es wird eine KI-Detektion mit Hilfe von *YOLOv4* entwickelt, welche es erlaubt, Bauteile in einer technischen Zeichnung zu erkennen und die Position zu bestimmen. Vorversuche haben drei wichtige Einflüsse für eine hohe Detektionsqualität herausgestellt: (I) Bildgröße und Auflösung, (II) die Anzahl der Trainingsdaten sowie (III) eine Definition der zu erkennenden Klassen, insbesondere der Label(-regionen).

Eine zweistufige Detektion liefert deutliche Vorteile im Hinblick auf die Detektionsqualität, da Details in großen technischen Zeichnungen mit einer Größe von bis zu DIN A0 sehr unscharf und klein dargestellt werden, wenn diese auf eine geeignete Größe für die Bilderkennung herunter skaliert werden, weshalb die Erkennung der Objekte bei einer einstufigen Version herabgesetzt wird. Es wird ein automatischer Wellengenerator mit Hilfe von *Python* entwickelt, welcher in kurzer Zeit gelabelte Trainingsdaten erzeugen kann. Diese synthetischen Daten werden mit realen Daten verglichen, indem drei Modelle aufgestellt werden: ein rein manuelles, ein synthetisches und ein Modell mit gemischten Trainings- und Validierungsdaten. Reale Zeichnungen, die händisch gelabelt werden, liefern die besten Detektionsergebnisse. Im Anschluss wird mit dem besten Modell eine teil-faktorielle Parameteranalyse mit Trainings- und Detektionsparametern durchgeführt, um das KI-Detektionsmodell weiter zu optimieren. Die Detektion ist in der Lage, Normteile und Maschinenelemente mit einer globalen Genauigkeit von mindestens 95% zu klassifizieren.

Es werden Kompetenzniveaus formuliert, um die Fähigkeiten, die zur Bewältigung des Moduls Technisches Zeichnen im Rahmen des Grundstudiums im Ingenieurwesen erforderlich sind, einordnen zu können. Anschließend wird das KI-Niveau anhand der zuvor aufgestellten Lernniveaus/Lernziel-Taxonomien ermittelt und mit denen der Studierenden verglichen. Daraufhin wird diskutiert, in welchen Lernszenarien oder wo die KI im Berufsumfeld als eine vorteilhafte Unterstützung dienen kann. Abschließend werden weitere Ansatzpunkte genannt, an denen in Zukunft an der KI-Detektion zur Verbesserung der Qualität und zur universellen Schöpfung des Einsatzpotentials gearbeitet werden sollte.

# Abstract

The aim of the work is a feasibility study of an AI-based object detection of components in technical drawings of mechanical engineering. Subsequently, the AI level is to be compared with that of students. Finally, teaching application scenarios are to be verified for AI.

An AI object detection based on *YOLOv4* is developed, which allows to recognise components in a technical drawing and to determine their position. Preliminary tests have identified three important influences for a high detection quality: (I) image size and resolution, (II) the number of training data as well as (III) a definition of the classes to be recognized, in particular of the labels.

The results show that a two-stage detection provides clear advantages with regard to the detection quality, since details in large technical drawings with a size of up to DIN A0 are displayed blurred and very small. This is why the recognition of objects is reduced in a single-stage version. An automatic shaft generator is being developed using *Python*, which can generate labeled training data in a short period of time. This synthetic data is compared to real data by setting up three models: a purely manual model, a synthetic model and a model with mixed training and validation data. It turns out that real drawings, labelled by hand, deliver the best detection results. Subsequently, a semi-factorial parameter analysis with training and detection parameters is performed with the best model to further optimize the AI object detection model. The detection is able to classify standard parts and machine elements with a mean overall accuracy of over 95%.

The competence levels are formulated in order to be able to classify skills that are required to pass the undergraduate technical drawing module in engineering. Moreover, the AI's taxonomy level is determined on the basis of the previously established taxonomy/difficulty levels and compared with those of the students. Then it is discussed in which learning scenarios or in which other fields AI can serve as a beneficial support in the professional environment. Finally, further projections are mentioned on which the future work should focus on to improve detection quality and to create universal application potential.

# Inhaltsverzeichnis

<b>Abkürzungs- und Formelverzeichnis</b>	<b>I</b>
<b>1 Einleitung</b>	<b>1</b>
<b>2 Stand der Technik</b>	<b>3</b>
2.1 Technische Zeichnung . . . . .	3
2.2 E-Learning . . . . .	4
2.3 Open Educational Ressources (OER) . . . . .	5
2.4 Constructive Alignment . . . . .	6
2.5 Spielkonzepte in der Lehre . . . . .	8
2.5.1 Gamification . . . . .	8
2.5.2 Serious Games . . . . .	9
2.5.3 Educational Games . . . . .	10
2.5.4 Game-based Learning . . . . .	10
2.6 Bildererkennung . . . . .	11
2.6.1 Parameter und Metriken für Objekterkennungssysteme . . . . .	13
2.6.2 OpenCV - Beispiel der Bildererkennung . . . . .	17
2.7 Künstliche Intelligenz (KI) . . . . .	20
2.7.1 Neuronales Netz (NN) . . . . .	21
2.7.2 Training der KI - Lernen (Deep Learning/ Machine Learning) . . . . .	22
2.7.3 YOLO (You Only Look Once) . . . . .	23
2.8 Bildererkennung in Bezug auf technische Zeichnungen . . . . .	26
<b>3 Vorgehen der Arbeit</b>	<b>29</b>
<b>4 Entwicklung einer KI-gestützten Objekterkennung für technische Zeichnungen</b>	<b>32</b>
4.1 Training . . . . .	32
4.1.1 Labeln von Trainingsdaten . . . . .	33
4.1.2 Definition der zu erkennenden Klassen . . . . .	34
4.1.3 Konfigurationsparameter Training . . . . .	40
4.2 Vorversuche zum Herausstellen der Einflussgrößen . . . . .	41
4.2.1 Auswertung der Vorversuche . . . . .	42
4.2.2 Optimierungsansätze der Detektionsqualität . . . . .	45
4.3 Optimieren der KI-Detektion . . . . .	46
4.3.1 Automatische Erstellung von Trainingsdaten . . . . .	46

4.3.2	Optimieren der Konfigurationsparameter und Neu-Definition von Klassen und Labeln . . . . .	48
4.3.3	Verbesserung der Hardwareleistung . . . . .	50
4.3.4	Analyse des Einflusses der Bildgröße und -auflösung . . . . .	51
4.4	Analyse und Auswertung der zweistufigen Modelle . . . . .	58
4.4.1	Auswertung des manuellen zweistufigen Modells . . . . .	59
4.4.2	Auswertung des zweistufigen synthetischen Modells . . . . .	63
4.4.3	Auswertung des zweistufigen gemischten Modells . . . . .	68
4.5	Variation der Trainings- und Detektionsparameter . . . . .	71
4.5.1	Gemischtes Modell mit Reduktion des synthetischen Bildanteils und erhöhter Bildgröße im Training . . . . .	71
4.5.2	Manuelles Modell mit erhöhter Bildgröße in der Detektion . . . . .	72
4.5.3	Manuelles Modell mit erhöhter Bildgröße im Training . . . . .	74
4.5.4	Manuelles Modell mit Variation der Detektionswerte Vertrauenswert und IoU-Schwelle . . . . .	77
4.6	Zusammenfassung der Detektionsergebnisse und Fazit . . . . .	84
4.7	Gegenüberstellung der Detektionsergebnisse zu den Ergebnissen aus der Literatur . . . . .	88
<b>5</b>	<b>Anforderungen des Technischen Zeichnens an den Ingenieur</b>	<b>90</b>
5.1	Anforderungen in der Lehre des Technischen Zeichnens . . . . .	90
5.1.1	Analyse der Modulhandbücher und Prüfungsordnungen in NRW	92
5.1.2	Anforderungen der Lehrenden . . . . .	92
5.1.3	Anforderungen der Studierenden . . . . .	94
5.1.4	Didaktische Rahmenbedingungen . . . . .	97
5.1.5	Weitere Anforderungen . . . . .	98
5.2	Modularer Aufbau des Lehr-/Lernangebots . . . . .	99
5.3	Definition der Kompetenzstufen . . . . .	101
5.3.1	Einordnung in den Konstruktionsprozess . . . . .	102
5.3.2	Grundlagen der TZ und Freihandzeichnungen . . . . .	102
5.3.3	Ansichten und Dreitafelprojektion . . . . .	103
5.3.4	Zielorientierte Bemaßung . . . . .	104
5.3.5	Schnitte und Zeichnungsgruppen . . . . .	105
5.3.6	Normung und GPS (Geometrische Produktspezifikation) . . . . .	106
5.3.7	Toleranzen und Passungen . . . . .	107
5.3.8	Normteile und Maschinenelemente (insbesondere Schraubenverbindungen) . . . . .	109
5.3.9	Wellenbearbeitung . . . . .	111
5.3.10	Lesen und Interpretieren Technischer Zeichnungen . . . . .	112

5.3.11	Einführung in CAD . . . . .	113
5.4	Zusammenfassung der Anforderungen und Synthese . . . . .	114
<b>6</b>	<b>Integration der KI-Objekterkennung in die Lehre</b>	<b>116</b>
6.1	Beschreibung des Objekterkennungsprogramms . . . . .	116
6.2	Diskussion zur Integration in die Lehre . . . . .	121
6.2.1	Unterstützungsfähigkeit bezüglich der im Technischen Zeichnen gelehrten Themen . . . . .	121
6.2.2	Anwendungsszenario für die potenzielle Integration in die Lehr- veranstaltungen . . . . .	127
6.2.3	Unterstützung für weitere Lernszenarien . . . . .	130
<b>7</b>	<b>Analyse und Bewertung des Niveaus der KI</b>	<b>134</b>
7.1	Analyse und Bewertung der Kompetenzstufen nach Thema . . . . .	134
7.1.1	Vergleich der erreichten Kompetenzstufen zwischen Studierenden, Ingenieur und KI . . . . .	137
7.1.2	Wo kann das Tool bzgl. der erreichten Kompetenzstufen generell im Maschinenbau eingesetzt werden? . . . . .	138
<b>8</b>	<b>Fazit und Ausblick</b>	<b>140</b>
	<b>Abbildungsverzeichnis</b>	<b>145</b>
	<b>Tabellenverzeichnis</b>	<b>152</b>
	<b>Literaturverzeichnis</b>	<b>164</b>
<b>A</b>	<b>Batch Datei zum Ausführen der KI-Detektion</b>	<b>165</b>
<b>B</b>	<b>Quellcode für das Unterstützungstool in Python mit Pycharm</b>	<b>166</b>
<b>C</b>	<b>Liste der Hochschulen aus NRW mit TZ-Bezug</b>	<b>182</b>
<b>D</b>	<b>Umfrageergebnisse der initialen Befragung zu TZ Digital.nrw</b>	<b>183</b>
<b>E</b>	<b>Ergebnisse aus der Abschluss- evaluation</b>	<b>188</b>
<b>F</b>	<b>Analyse der Module an Hochschulen in NRW mit Bezug auf TZ</b>	<b>213</b>
<b>G</b>	<b>Auswertung der ME in NRW</b>	<b>215</b>
<b>H</b>	<b>ChatGPT zu Gestaltabweichungen in der geometrischen Produktspezifi- kation (GPS)</b>	<b>219</b>

## Abkürzungs- und Formelverzeichnis

### Abkürzungen und Akronyme

<b>AP</b>	Average Precision (durchschnittliche Genauigkeit)
<b>AR</b>	Augmented Reality
<b>BB</b>	Bounding Box (Markierte Region)
<b>BMBF</b>	Bundesministerium für Bildung und Forschung
<b>BMWK</b>	Bundesministeriums für Wirtschaft und Klimaschutz
<b>BRIEF</b>	Binary Robust Independent Elementary Features
<b>CAD</b>	Computer Aided Design (computergestütztes Design)
<b>CAE</b>	Computer Aided Engineering (computergestützte Produktentwicklung)
<b>CC</b>	Creative Commons (Lizenz)
<b>CNN</b>	Convolutional Neural Network (gefaltetes Neuronales Netz)
<b>Conf.</b>	Confidence Value (Vertrauenswert)
<b>CP</b>	Credit Points (Leistungspunkte)
<b>DGBL</b>	Digital game-based learning
<b>DIN</b>	Deutsche Institut für Normung e.V
<b>Dpi</b>	Dots per inch (Punkte pro Zoll)
<b>ECTS</b>	European Credit Transfer and Accumulation System
<b>EN</b>	Europäische Norm
<b>FAQ</b>	Frequently Asked Questions (häufig gestellte Fragen)
<b>FLOP</b>	Floating Point Operations (Fließkommaoperationen)
<b>FN</b>	False negative (Falsch negativ)
<b>FP</b>	False positive (Falsch positiv)
<b>GB</b>	Gigabyte
<b>GIoU</b>	Global Intersection over Union
<b>GPS</b>	Geometrische Produktspezifikation
<b>GPU</b>	Graphics Processing Unit (Grafikeinheit)
<b>IKT</b>	Informations- und Kommunikationstechnologien

<b>ILO</b>	Intended Learning Outcomes (Gewünschte Lernergebnisse)
<b>IoU</b>	Intersection over Union (Überlappung der Vereinigung)
<b>ISO</b>	International Organization for Standardization
<b>H5P</b>	HTML5 Package
<b>KI</b>	Künstliche Intelligenz (engl. AI - Artificial Intelligence)
<b>LMS</b>	Lern Management System
<b>LP</b>	Leistungspunkte
<b>mAP</b>	Mean Average Precision (durchschnittliche gemittelte Genauigkeit)
<b>ME</b>	Maschinenelemente
<b>ML</b>	Machine Learning (Maschinelles Lernen)
<b>MOOC</b>	Massive Open Online Course
<b>MR</b>	Missing Rate (Verlustrate)
<b>NN</b>	Neuronales Netz
<b>NRW</b>	Nordrhein-Westfalen
<b>OA</b>	Overall Accuracy (globale Genauigkeit)
<b>OBTL</b>	Outcome based teaching and learning
<b>ODA</b>	Objekt Detektionsalgorithmus
<b>OER</b>	Open Educational Ressources
<b>OERSI</b>	Open Educational Resources Search Index
<b>OpenCV</b>	Open Source Computer Vision Library
<b>ORB</b>	Oriented FAST and rotated BRIEF
<b>ORCA.nrw</b>	Open Resources Campus NRW
<b>pdf</b>	Portable Document Format
<b>Pre</b>	Precision (Präzision)
<b>QR</b>	Quick response
<b>R-CNN</b>	Region Based Convolutional Neural Networks
<b>Rec</b>	Recall
<b>RK</b>	Rillenkugellager
<b>ROI</b>	Region of Interest (Interessensregion)
<b>RWDR</b>	Radialwellendichtring

<b>SB</b>	Sicherungsblech
<b>SBN</b>	Sicherungsblechnut
<b>SIFT</b>	Scale-Invariant Feature Transform
<b>SK</b>	Schräggugellager
<b>SR</b>	Sicherungsring
<b>SSD</b>	Single Shot Detector
<b>SURF</b>	Speed-Up Robust Features
<b>SWS</b>	Semesterwochenstunden
<b>TN</b>	True negative (richtig negativ)
<b>TP</b>	True positive (Richtig positiv)
<b>TZ</b>	Technische Zeichnung
<b>VR</b>	Virtual Realität
<b>VRAM</b>	Video Random Access Memory
<b>VW</b>	Vertrauenswert
<b>WM</b>	Wellenmutter
<b>XR</b>	Extended Reality (Erweiterte Realität)
<b>YOLO</b>	You only look once (KI-Detektionsalgorithmus)

## Formeln und Indizes

Symbol	Definition	Wertebereich
$h$	relative Höhe	$[0;1]$
$n$	Anzahl (natürliche Zahl)	$n \in \mathbb{N}$
$n_k$	Anzahl der Klassen	$n_k \in \mathbb{N}$
$P$	Wahrscheinlichkeit	$[0;1]$
$px$	Pixel	$px \in \mathbb{N}$
TD	Anzahl Trainingsdaten (natürliche Zahl)	$[0;1]$
$w$	relative Breite	$[0;1]$
$x$	relative Position auf der Abzisse	$[0;1]$
$y$	relative Position auf der Ordinate	$[0;1]$
$\bar{Y}_n$	Ausgangssignal	$\bar{Y}_n \in \mathbb{R}^n$

# 1 Einleitung

In der gegenwärtigen Situation ist der Begriff Künstliche Intelligenz (KI) überall wahrzunehmen und aus der technischen Welt nicht mehr wegzudenken. Bereits im Jahre 2019 nutzten laut des *Bundesministeriums für Wirtschaft und Klimaschutz (BMWK)* innerhalb der Innovationserhebung bis zu 20% der Unternehmen aus der Branche der Informations- und Kommunikationstechnologien (IKT) KI. Dies wird anhand der Indikatoren zur Verbreitung des Einsatzes ermittelt [Bun19]. Speziell der Begriff *ChatGPT* (Generative Pre-trained Transformer) ist aktuell fast überall anzutreffen und wird durch *OpenAI* geprägt. *OpenAI* ist eine gemeinnützige Organisation und wurde 2015 mit einer Investition von einer Milliarde Dollar gegründet, um die Nutzung der KI öffentlich zugänglich zu machen, und soll laut eigenen Aussagen positive Auswirkungen auf die Menschheit mit sich bringen [Lew15]. Erst kürzlich veröffentlichte *OpenAI* einen technischen Bericht über die Entwicklung von *GPT-4*. *GPT-4* ist ein „multimodales Modell, das Bild- und Texteingaben akzeptiert und Textausgaben produziert“ [Ope23]. Es zeige sich eine Leistung auf menschlichem Niveau bei verschiedenen beruflichen und akademischen Benchmarks, einschließlich des Bestehens einer simulierten Anwaltsprüfung mit einer Punktzahl, die in den oberen 10% der Teilnehmenden liege [Ope23].

Neben dem Sprachmodell *GPT-4* werden auch in anderen Themengebieten andere KI-Modelle entwickelt und genutzt. Beispielsweise wird in der Bildverarbeitung auf trainierte KI-Modelle zurückgegriffen. Ein häufig verwendeter Detektionsalgorithmus ist *YOLO* (You only look once). Dieser wird bereits in der Automobilindustrie oder bei der Entwicklung des autonomen Fahrens eingesetzt [Sar21; Ata23; Dod18]. Der *YOLO*-Algorithmus kann auch zur Analyse von technischen Zeichnungen eingesetzt werden. Teil dieser Arbeit ist eine Machbarkeitsstudie zur Erkennung von Bauteilen in technischen Zeichnungen. In diesen Zeichnungen sind in der Regel viele genormte Bauteile vorhanden, weshalb sie sich gut für die Bildererkennung eignen.

In der Ausgangssituation stellt sich die Frage, wo die KI als Unterstützungseinheit im Ingenieurwesen dienen kann. Die Multimodalität, also die Art der Kommunikation, durch textliche, auditive, sprachliche, räumliche und visuelle Modalitäten Textnachrichten zu

formulieren [Mur13], wird hierbei bereits durch *ChatGPT* bzw. *GPT-4* abgedeckt. Die Möglichkeit der Bildverarbeitung zur Unterstützung von Ingenieur Tätigkeiten, indem visuelle Ausgaben erzeugt werden, bietet die KI als weiteren Aspekt an. Es gibt die Möglichkeit, dass die KI bei der Erstellung, Verarbeitung und Optimierung von technischen Zeichnungen im Ingenieurwesen unterstützen kann. Hieraus gehen besonders zwei Fragen hervor. Welche Vorteile ergeben sich, wenn eine KI im Vergleich zu klassischen Strategien der Bildverarbeitung eingesetzt wird und welchen Kompetenzstand kann die KI erreichen, sodass eine Unterstützung zweckmäßig ist.

Um diese Fragen zu diskutieren wird zunächst der Stand der Technik besonders im Hinblick auf die Verwendung von KI im Modul Technisches Zeichnen bzw. in Bezug auf technische Zeichnungen, auch außerhalb des Maschinenbaus, erörtert. Es wird eine Methode gesucht, anhand dessen das Niveau der KI im Vergleich zu Studierenden und Ingenieur\*innen wissenschaftlich untersucht werden kann. Das Ziel der Arbeit ist die Entwicklung einer KI-Objekterkennung für technische Zeichnungen sowie die Bewertung des aktuellen KI-Niveaus.



kann vor allem die Anordnung und das Zusammenspiel der Maschinenelemente abgelesen und deren Funktion interpretiert werden. Es handelt sich hier um ein Getriebe, das aus zwei Hauptachsen besteht, die um  $90^\circ$  versetzt sind, und somit eine Kraftübertragung um einen rechten Winkel versetzt erlaubt. Um zu verstehen, welche Funktion die Maschine bzw. die Unterbaugruppen erfüllen, ist es erforderlich, dass die einzelnen Bauteile innerhalb der Zeichnung erkannt und benannt werden können. Es ist die Grundbasis für das Verständnis und die weitere Analyse.

## 2.2 E-Learning

E-Learning, d.h. elektronisch unterstütztes Lernen, hat durch die Covid-19 Pandemie einen neuen Stellenwert innerhalb des Bildungssektors erreicht, weil Lehrende und Lernende aufgrund der Covid-19 Pandemie gezwungen waren, darauf zurückzugreifen. Auf der einen Seite konnten sowohl Studierende als auch Lehrende Ihre Medienkompetenzen ausbauen, auf der anderen Seite zeigten Untersuchungen, dass der Arbeitsaufwand dadurch auf beiden Seiten deutlich anstieg. [Maa22]

Mit dem Begriff E-Learning werden vor allem die elektronischen und digitalen Medien in Verbindung gebracht. E-Learning ist jedoch nicht zu verwechseln mit dem elektronischen Lernen, also elektronisch begründetes und vollzogenes Lernen. Dies gebe es nur in elektronischen Systemen, z. B. in Robotern, „*die mit Systemen künstlicher Intelligenz ausgestattet sind*“ [Arn04]. Vielmehr bedeutet dieses ein Arrangieren mit elektronischen Medien und verschiedenen Lernkonzepten, wie dem Blended Learning oder dem Flipped Classroom [Arn04]. Die Kombination von E-Learning und Präsenzlehre ist eine zentrale didaktische Aufgabe bei der Gestaltung moderner Bildung. „*Blended Learning ist die strategische Kombination von Online- und Präsenzlernen*“ [Pic21]. Es ist ein Lehrkonzept, welches die verschiedenen Formate sowohl inhaltlich als auch organisatorisch aufeinander abstimmt. Der Horizon Report aus dem Jahre 2016 hebt das Blended Learning als einen der wichtigsten Trends in der Hochschulbildung hervor [Joh16]. Es kombiniert die positiven Effekte der beiden Lernstrategien Online- und Präsenzlernen und zeigt „*verbesserte Ergebnisse, obwohl die Bedingungen tendenziell mehr Unterrichtszeit, Unterrichtsressourcen und Elemente beinhalten, die die Peer-Interaktion zwischen den Lernenden fördern*“ [Pic21]. Im Gegensatz dazu nutzt das hybride Lernkonzept die gleichzeitige Durchführung von Präsenz- und digitalem Lernen [Cho15].

Ein Rahmen für Planungsphasen und Arbeitsschritte zur Gestaltung virtueller Lernmodule zur Erstellung von E-Learning Materialien wird von Arnold et al. [Arn04] bereitgestellt. Es wird ein chronologisches Verfahren mit verschiedenen Aspekten wie den fachlichen Anforderungen, der didaktischen Struktur, der formalen Struktur einschließlich des Lernraums und der operativen Struktur berücksichtigt. Eine operative

Struktur beschreibt kognitive Prozesse, die eine Abstraktion der Wahrnehmung vornehmen. Darüber hinaus werden einige wichtige Anforderungen genannt, die erfüllt werden müssen: Zugänglichkeit, Qualitätsmanagement, Anpassungsfähigkeit, Metadaten, Evaluation, didaktisches Konzept und ein Konzept zur Konsolidierung. Die Zugänglichkeit beschreibt das barrierefreie Arbeiten mit dem Material. Die Metadaten geben wichtige Informationen zum Inhalt, Thema, zur Lizenz etc. an. Das didaktische Konzept sorgt dafür, dass die Inhaltsvermittlung mit den Lernaktivitäten und Lernzielen einhergeht. Eine Evaluation sollte durchgeführt werden, um zu ermitteln, inwiefern die Entwicklungsziele erreicht wurden und um Optimierungsmaßnahmen einleiten und durchführen zu können. [Arn04]

Bei der Planung der Rahmenbedingungen zur Entwicklung von E-Learning Kursen sind die finanziellen Rahmenbedingungen, der Zeitrahmen, die personellen Kapazitäten und technische Bedingungen wichtige Faktoren [Arn04; RR03]. Aber auch die didaktische Konzeptionierung nimmt einen wichtigen Stellenwert bei der Planung ein. Dabei hat das didaktische Lehrmodell des *Constructive Alignment* in den letzten Jahren an Bedeutung gewonnen, welches in Unterkapitel 2.4 näher behandelt wird.

### 2.3 Open Educational Ressources (OER)

Open Educational Ressources (OER) sind offene Bildungsressourcen bzw. Bildungsmaterialien, die unter einer offenen Lizenz stehen, die den freien Zugang sowie die freie Nutzung, Bearbeitung und Weitergabe durch Dritte ohne oder mit geringen Einschränkungen erlauben [UNE19]. Die Lizenz richtet sich dabei nach den Definitionen der *Creative Commons*. Dies ist eine gemeinnützige Organisation, die vorgefertigte Lizenzverträge bereitstellt und die gemeinsame Nutzung von Wissen erleichtern möchte. Es gibt sieben Lizenztypen, zwischen denen unterschieden wird:

1. CC0 - Kein Copyright
2. CC BY - Namensnennung
3. CC BY-SA - Namensnennung - Weitergabe unter gleichen Bedingungen
4. CC BY-ND - Namensnennung - Keine Bearbeitung
5. CC BY-NC - Namensnennung - Nicht kommerziell
6. CC BY-NC-SA - Namensnennung - Nicht-kommerziell - Weitergabe unter gleichen Bedingungen
7. CC BY-NC-ND - Namensnennung - Nicht-kommerziell - Keine Bearbeitung

Für die Erstellung von OER sind die ersten drei Lizenztypen erlaubt, wobei eine CC0 Lizenz angestrebt werden sollte, damit die Weiterverarbeitung für die Nachnutzen-

den erleichtert wird. Im Jahr 2019 veröffentlichte das *BMBF (Bundesministerium für Bildung und Forschung)* die OER-Strategie mit den Handlungszielen Anreizsysteme zur Erstellung und Nutzung von OER zu schaffen, Kooperationen zu fördern und Bildungsinstitutionen zum Zwecke der Chancengleichheit zu unterstützen [Bun22]. Zu dieser Zeit wurde die Förderrichtlinie OERContent.nrw ins Leben gerufen, die die Erstellung von Lehr-/Lernmaterialien als OER für das Landesportal ORCA.nrw fördert. Auf diesem Landesportal werden öffentliche Lernmaterialien frei zur Verfügung gestellt und können dort auch angepasst werden. Es können auch ganze Kurse zur Verfügung gestellt werden, die teilweise als Massive Open Online Courses (MOOC) bezeichnet werden. Jedoch ist ein MOOC nicht immer mit freier Lizenz verfügbar, sondern es gibt weltweit auch kommerzielle MOOC-Angebote. Grundsätzlich sollen OER und MOOCs die Bildung wie z.B. die Hochschullehre öffentlich zugänglich machen und die Zugänglichkeit beziehungsweise die Barrierefreiheit erhöhen [UNE02; WI12; Sch13]. Das Menschenrecht auf Bildung soll für alle gewährt sein und Kooperationen sollen angeregt werden. Die Begriffe OER und MOOC sollen in ihrer Ursprungsidee beide die Qualität der Lehre verbessern [Arn04; Mei17; Deu14].

## 2.4 Constructive Alignment

Das *Constructive Alignment* ist ein didaktisches Prinzip, welches im Folgenden erläutert wird. Lehrende planen ihre Veranstaltungen in der Regel von den fachlichen Inhalten her – Studierende gehen beim Lernen aber von den konkreten Anforderungen der Prüfung aus. Diese unterschiedlichen Perspektiven können dazu führen, dass Lernen und Lehren aneinander vorbeigehen und dies von beiden Seiten als unbefriedigend empfunden wird. Das didaktische Modell des *Constructive Alignment* hilft, bei der Konzeption einer Veranstaltung nicht nur Lernziele mit den Lehr- und Lernmethoden abzustimmen, sondern auch die Prüfung in diese Planung einzubeziehen [Dil23c].

*Biggs* und *Tang* treiben eine Verlagerung des Schwerpunkts vom Lehrenden auf den Lernenden voran und konzentrieren sich insbesondere auf die Lernergebnisse, welche die Lernenden erreichen sollen. Die Basis und der Startpunkt sind dabei folglich kompetenzorientierte Lernziele (Intended Learning Outcomes (ILO)). ILOs sind Lernziele, die ein Niveau des Verständnisses und der Leistung angeben, welche Lehr- und Lernerfahrungen erreicht werden sollen. Diese Lernziele sind dann die Grundlage für die Gestaltung aller Lern- und Lehraktivitäten und Lernerfolgskontrollen (siehe **Abbildung 2.2**). Sie geben an, welche Fähigkeiten die Studierenden nach einer Lerneinheit besitzen sollten. Es geht insgesamt um Kompetenzen, also Handlungsfähigkeiten bzw. -dispositionen (Outcomesbased teaching and learning - OBTL). [BT11]

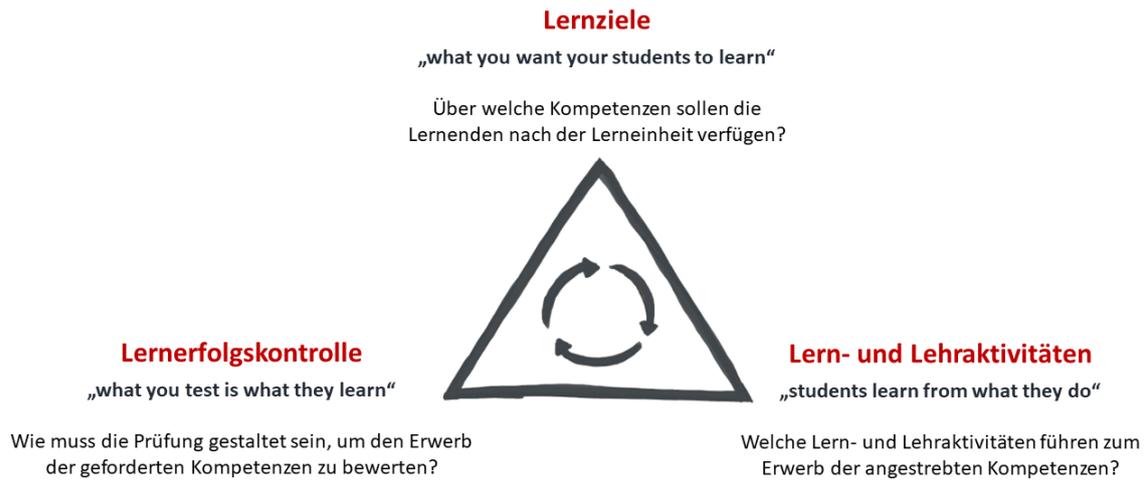


Abbildung 2.2: Die drei Standbeine des *Constructive Alignment* [Dil23c]

Die kognitiven Ebenen (Lernzieltaxonomien) werden üblicherweise nach Bloom definiert und reichen vom reinen Wissen über das Verstehen bis hin zur Bewertung und Beurteilung [BE74; And94]. Eine Auflistung von geeigneten Verben und eine Veranschaulichung der Komplexitätsstufen ist der **Abbildung 2.3** zu entnehmen. Kompetenzorientierte Lernziele bestehen aus:

1. Einem Einleitungsteil, der auf den Zeitrahmen der Zielerreichung verweist,
2. einem Adverb, das die Qualität (z.B. Selbstständigkeit) der Handlung bestimmt,
3. der Beschreibung des Inhaltes bzw. des Themas, auf das sich die Handlung bezieht,
4. dem Verb zur kognitiven Stufe (Lernzieltaxonomie), die erreicht werden soll.

Beispiel: Nach dem Absolvieren der Lerneinheit sind die Studierenden in der Lage (1), selbstständig (2) die Bemaßung eines einfachen Bauteils normgerecht (3) auszuführen (4) [BT11; Dil23c]. Diese Lernziele werden direkt mit den Lern- und Lehraktivitäten sowie der Lernerfolgskontrolle abgestimmt. Die abschließende Benotung richtet sich nach der Erreichung der ILOs. Eine mögliche Bewertungsskala ist die Folgende [BT11]:

- A. Befähigung zur Reflexion, realistische Selbsteinschätzung, Fähigkeit zur Formulierung und Anwendung von Theorie auf problematische Unterrichtssituationen anwenden, klare Beherrschung der Inhalte.
- B. Kann die Theorie auf die Praxis anwenden, ein ganzheitliches Verständnis von Kurs und Komponenten, knapp an A gescheitert.
- C. Kann die wichtigsten Theorien erklären, und andere Themen grundlegend beschreiben, knapp an B gescheitert.
- D. Kann nur einige Theorien erklären, knapp an C gescheitert.
- F. Schlechter als D, „Plagiat“.



<b>erinnern</b>	<i>aufzählen, definieren, berichten, identifizieren, darstellen, bezeichnen, sammeln, sichten, tabellarisieren, zitieren, benennen, erkennen, abrufen, ...</i>
<b>verstehen</b>	<i>beschreiben, gegenüberstellen, abschätzen, verknüpfen, unterscheiden, einschätzen, diskutieren, erweitern, interpretieren, veranschaulichen, klassifizieren, zusammenfassen, erklären, ...</i>
<b>anwenden</b>	<i>vorführen, berechnen, vervollständigen, abbilden, lösen, modifizieren, einen Zusammenhang herstellen, verändern, anwenden, experimentieren, entdecken, ausführen, implementieren, ...</i>
<b>analysieren</b>	<i>auftrennen, ordnen, verbinden, kategorisieren, anordnen, analysieren, unterteilen, systematisch vergleichen, differenzieren, strukturieren, ableiten, beimessen, ...</i>
<b>evaluieren</b>	<i>beurteilen, entscheiden, einstufen, werten, erproben, messen, empfehlen, evaluieren, überzeugen, überprüfen, kritisch bewerten, herausfiltern, einschätzen, unterschiedlich behandeln, untermauern, schließen, argumentieren, ...</i>
<b>erschaffen</b>	<i>entwickeln, planen, produzieren, kombinieren, integrieren, umgestalten, ersetzen, erstellen, gestalten, erfinden, mit Annahmen arbeiten, zusammensetzen, ausarbeiten, bereitstellen, verallgemeinern, umformulieren, erzeugen, ...</i>

Abbildung 2.3: Beispielverben für die Einordnung der Lernzieltaxonomie [Dil23c]

## 2.5 Spielkonzepte in der Lehre

In diesem Unterkapitel werden verschiedene Spielkonzepte vornehmlich für die Lehre vorgestellt, die die Motivation der Lernenden erhöhen sollen. Die Definitionen zu den jeweiligen Spielkonzepten sind in der vorliegenden Literatur nicht immer identisch. Daher wird teilweise die Schnittmenge der Definitionen als Beschreibung für ein Spielkonzept herangezogen und die Unterschiede werden herausgestellt.

### 2.5.1 Gamification

Der Begriff Gamification wird als ein Spielelement angesehen, welches dazu genutzt wird, Ziele auf einer übergeordneten Ebene zu erreichen. Diese Ebene ist bspw. eine Lehrveranstaltung, in derer einzelne Spielelemente genutzt werden, um die intrinsische Motivation der Lernenden zu steigern, damit die Lernziele effektiver erreicht werden. Die Unterscheidung verschiedener Spielkonzepte ist in **Abbildung 2.4** gezeigt. Beim Gamification wird anhand des „Gamings“ im Gegensatz zum freien Spiel ein übergeordnetes Ziel verfolgt. Beim freien Spiel wird nach dem „try and error-Prinzip“ vorgegangen und es gibt häufig keine Regeln (Unterhaltungsfaktor primär). [Det11; TZ04]

*Zichermann* und *Cunningham* definieren den Begriff Gamification als „die Anwendung von spielerischem Denken und Spielmechaniken, um Nutzer zu motivieren und

Probleme zu lösen“ [ZC11]. Während *Deterding* [Det11] sich auf die Nutzung von einzelnen Spielelementen bezieht, schließen *Zichermann* und *Cunningham* die Nutzung von vollumfänglichen Spielen ein. Game Design Elemente bestünden aus den Elementen „Mechanik“, „Dynamik“ und „Ästhetik“. Die Mechanik beschreibt die spielinterne Umwandlung der Benutzereingaben in definierte Ausgaben. Die Dynamik lässt sich als die Interaktion des Spielers mit den Spielmechaniken darstellen. Bei der Ästhetik handelt es sich um die grafische Umsetzung des Spiels. Eine andere Definition umschreibt Gamification als „ein Prozess zur Verbesserung einer Dienstleistung mit der Nutzung von Spielerlebnissen, um die Gesamtwertschöpfung des Nutzers zu unterstützen“. [HH12; ZC11]

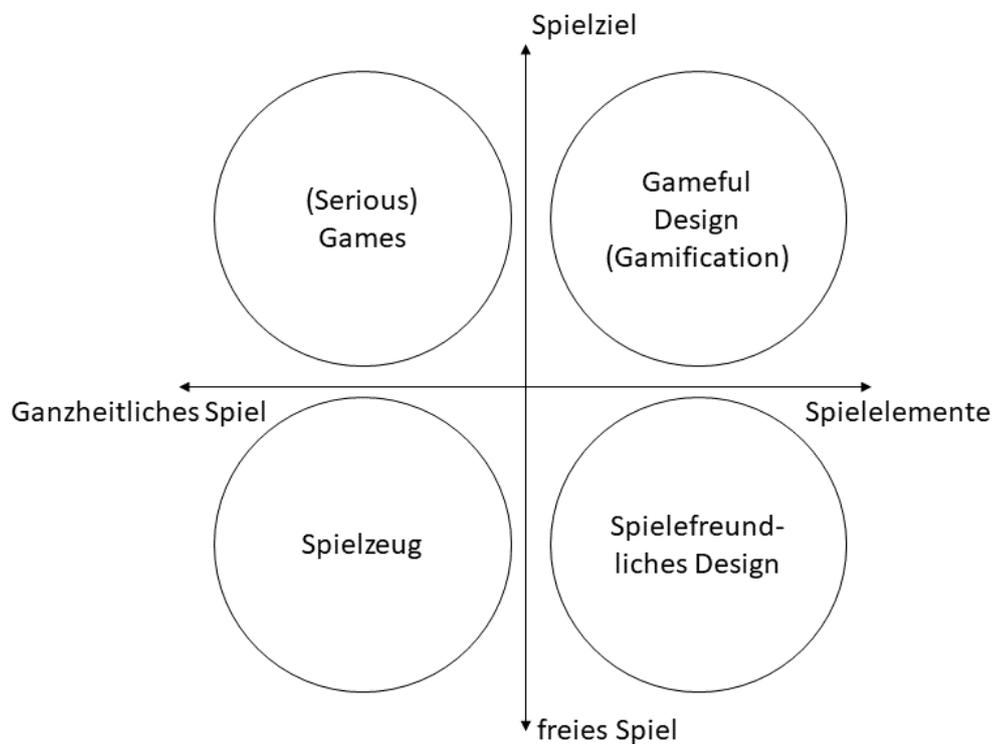


Abbildung 2.4: Einordnung der Spielkonzepte nach [Det11]

### 2.5.2 Serious Games

Serious Games verfolgen in der Regel ebenfalls ein übergeordnetes Ziel. Es gibt hierzu viele Definition, die sich geringfügig unterscheiden. Einige Autoren sagen, dass die Unterhaltung nicht im Vordergrund stehe, gerade bei der Nutzung in der Lehre [SM07; YB10; WW10; Rit09; Pop11], während andere den Unterhaltungsfaktor als entscheidende Komponente ansehen, die das primäre Ziel bei der Erstellung eines Spiels vorsieht [Zyd05; Bec21]. Die meisten Autoren stimmen jedoch überein, dass es grundsätzlich ein Lernziel gibt, das durch das Spiel erreicht werden soll. Der Unterschied der Definitionen liegt in der Priorität dieses Spielziels.

### 2.5.3 Educational Games

Viele Autoren definieren Educational Games als Unterbegriff von Serious Games, mit dem Unterschied, dass ein Lernziel adressiert wird. *Hoblitz* schreibt Educational Games dem institutionell-professionellen Bereich zu und beschreibt es als „Serious Games-Applikationen, die bestimmte Lernziele im Sinne einer Wissensvermittlung in die Spielmechanismen integrieren und dadurch, so die Idealvorstellung, zu bestimmten affektiven, kognitiven oder motivationalen Lerneffekten führen“ [Hob14]. Educational Games werden im pädagogischen Kontext genutzt, um Wissen, Fähigkeiten oder bestimmte Verhaltensweisen zu vermitteln [WR14].

### 2.5.4 Game-based Learning

Der Begriff Game-based Learning wird häufig mit dem Wort „digital“ davor ergänzt und als Synonym angesehen, obwohl auch nicht-digitale Spielformen mit einbezogen sind [Nai14]. Zunächst prägte Prensky den Begriff und erklärte es als die Kombination von Bildungsinhalten und Videospiele [Pre01]. Auch hier liegen Definitionen vor, die der der Educational Games ähneln, nämlich das Aneignen von Kenntnissen und/oder Fähigkeiten [Bec21]. Auch die weiteren Beschreibungen haben eine große Schnittmenge mit den eben beschriebenen Definitionen in Bezug auf die Educational Games.

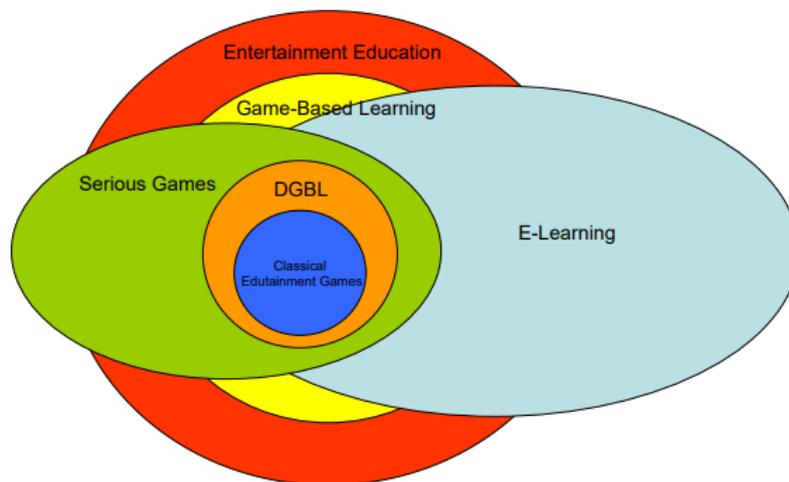


Abbildung 2.5: Überblick über die Spielekonzeptlandschaft [BB10]

Insgesamt beschreibt die **Abbildung 2.5** die Schnittmenge der Definitionen. Digital Game-Based Learning ist eine Teilmenge der Serious Games und des E-Learnings. Die Anordnung des Game-Based Learning und der Begriff der Entertainment Education kann hinterfragt werden. Alle Spielkonzepte besitzen eine Schnittmenge zum E-Learning. Nach dieser Abbildung 2.5 sind die Begriffe digital Game-based learning (DGBL) und Game-based learning nicht gleichzusetzen, sondern besitzen nur eine geringe Schnittmen-

ge, weil nicht digitale Spiele ein größeres Spektrum abdecken. Hier wird ein Unterschied zu anderen Autoren deutlich, weil Serious Games eine Schnittmenge sowohl mit unterhaltenden als auch lernzielorientierten Spielen besitzen. Damit widerspricht diese Abbildung der Definition der o.g. Autoren, weil nicht nur unterhaltende Spielziele als Primärziel adressiert werden. Es wurde gezeigt, welche Konzepte und Spielziele für die Integration in die Lehre verwendet werden sollten, um Lernziele primär zu adressieren.

## 2.6 Bilderkennung

Die Bilderkennung ist ein Teilgebiet der Bildverarbeitung und identifiziert charakteristische Merkmale eines Bildes, um spezielle Details oder Objekte erkennen zu können [Nis20]. Es können bspw. Personen, Orte, Objekte und Schriften in Bildern erkannt werden. Bei der Bilderkennung wird eine Pixel- sowie Musteranalyse (pattern Recognition) angewendet, damit bestimmte Objekte innerhalb des Bildes erkannt und die Position bestimmt sowie einer zuvor definierten Kategorie zugeordnet werden [KT08]. Die Bildverarbeitung kann in fünf Schritte unterteilt werden, nämlich die Bilderfassung, die Vorverarbeitung, die Segmentierung, die Merkmalsextraktion und die Klassifikation. Diese Schritte werden im weiteren Verlauf genauer beschrieben. [Wer21]

Die Bilderfassung beschreibt die Aufnahme eines Bildes und diskretisiert die Beleuchtungsstärke in einer zweidimensionalen Rasterung. Die Erfassung kann bspw. mit einer Kamera erfolgen, die eine Szene aufnimmt. Hier wird der gewünschte Bildausschnitt festgelegt. Während der Aufnahme eines Bildes können bereits Filter zum Einsatz kommen, welche die Beleuchtung beeinflussen. Bei digital erzeugten Bildern entfällt der Schritt der Bilderfassung. Die Vorverarbeitung ändert das aufgenommene Bild insofern, als dass Beleuchtungsunterschiede ausgeglichen werden. Dies geschieht mit Hilfe von Filtern oder Kompensationsverfahren. Dadurch kann ein Erkennen von Merkmalen in den darauffolgenden Schritten erleichtert werden. [Wer21]

Die Segmentierung teilt das Bild mit Hilfe von Merkmalen in einheitliche Bereiche (Segmente) ein. Hierfür kommen verschiedene Verfahren wie die multivariate statistische Klassifikation, die Binärbilderzeugung, statistische Klassifikatoren, geometrische Klassifikatoren, neuronale Netze oder Operatoren auf Basis der *fuzzy logic* zum Einsatz. Die Segmentierung wird eingesetzt, um Datenmengen zu minimieren, sodass die Daten kompakter sind. Ein Beispiel zur Kompensation einer ungleichmäßigen Beleuchtung sowie zum Aussortieren nicht benötigter Bildpunkte mittels der Schwellenwertsegmentierung ist in **Abbildung 2.6** gezeigt. [Nis20]

In der Merkmalsextraktion werden Parameter definiert, um ein Objekt beschreiben und später klassifizieren zu können. Diese Parameter müssen bestimmte Bedingungen erfüllen, sodass ein Objekt möglichst präzise erkannt werden kann, wenn Störfaktoren vorliegen

[Erh08]. Am besten sind Objekte zu erkennen, deren Regionen konstante Grauwerte besitzen (z. B. Blob-Detection). In der Realität kommen solche Fälle, beispielsweise bedingt durch Rauschen, ungleichmäßige Beleuchtung oder durch einen inhomogenen Hintergrund, selten vor [Jä12]. Bei komplexeren Anwendungen müssen Objekte anhand mehrerer Merkmale von dem Hintergrund zu unterscheiden sein, wodurch mehr als ein Merkmalsbild für eine Modellberechnung erforderlich sein kann. Man erhält so ein vektorielles Eigenschaftsbild [Jä12].

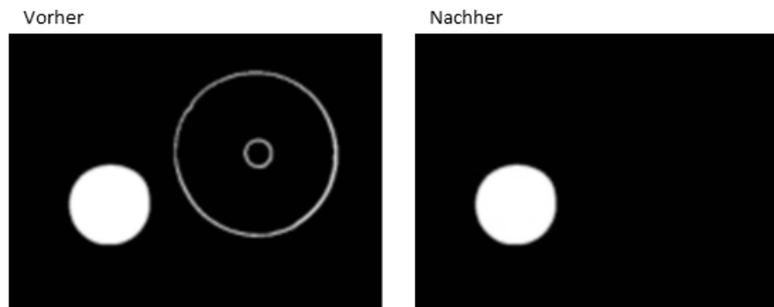


Abbildung 2.6: Segmentierung durch Schwellwertbildung nach [Nis20]

Bei der Klassifikation wird ein Bild anhand der vorher durchgeführten Schritte analysiert und geprüft, ob und inwiefern die Parameter der Merkmalsextraktion mit den Parametern einer Klasse übereinstimmen. Anhand des Verhältnisses der Übereinstimmung wird ein Objekt einer gefundenen Klasse zugeordnet [Jä12; Erh08]. In **Abbildung 2.7** ist ein solcher Merkmalsraum aufgezeigt, in dem sich verschiedene Aktivierungsvektoren (blau und rot) befinden. Die beiden Klassen sind getrennt und eine Entscheidungsgrenze ist eingetragen (blaue Linie). Liegt ein Punkt oberhalb der blauen Linie, kann er der Klasse „rot“ zugeordnet werden.

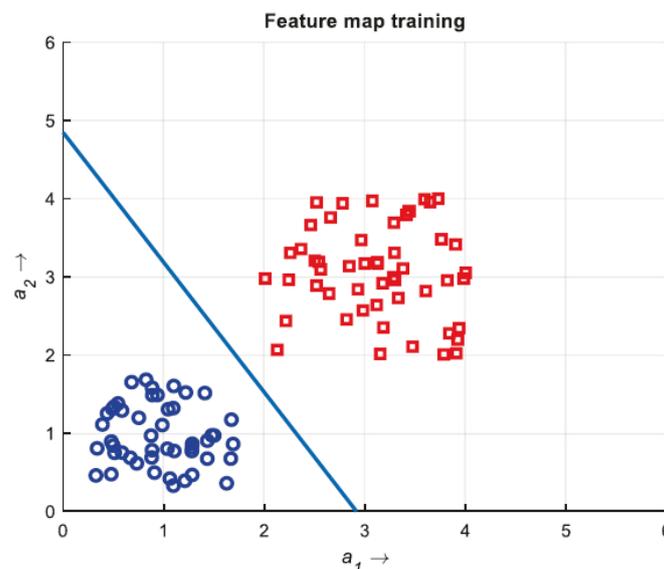


Abbildung 2.7: Zweidimensionaler Merkmalsraum mit Aktivierungsvektoren [Nis20]

Es sollen zwei Erkennungsstrategien vorgestellt werden, um die Klassifikation näher zu beschreiben. Die erste Bilderkennungsstrategie ist unter anderem als Mustererkennung bekannt. Hier werden logische Zusammenhänge gesucht und anhand dessen werden die Objekte gruppiert [Nis20; Erh08]. Bei der Mustererkennung werden neben der Segmentierung auch Zusammenhänge zwischen den Objekten ermittelt [KT08]. Ein Objekt wird anhand von Referenzmustern in einem Bild detektiert. Das Objekt muss im Voraus bekannt sein [Hah12]. Die zweite Strategie ist die Vektorerkennungsstrategie, bei der Vektoren bestimmten Klassen zugeordnet werden.

### 2.6.1 Parameter und Metriken für Objekterkennungssysteme

Es gibt Metriken und Parameter für Objekterkennungssysteme, die eine Klassifikation eines Objektes bewerten, um somit die Güte der Objekterkennung beurteilen zu können. Diese werden in diesem Abschnitt vorgestellt. Zur Einleitung der nächsten Begrifflichkeiten wird die Wahrheitsmatrix angeführt, welche die vier möglichen Ergebnisse einer Objekterkennung in einer Tabelle darstellt (siehe **Tabelle 2.1**).

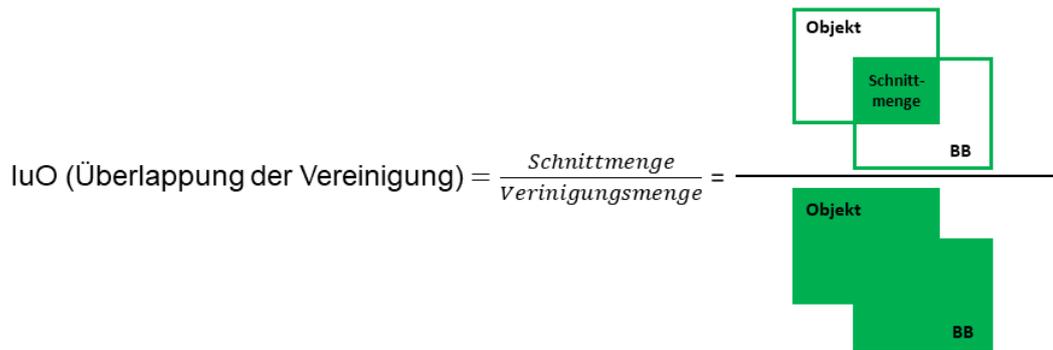
Tabelle 2.1: Wahrheitsmatrix zur Beurteilung der Objekterkennung

	Objekt vorhanden		
	Erkennung	Ja	Nein
Vorhersage	Ja	Richtig positiv	Falsch positiv
	Nein	Falsch negativ	Richtig negativ

#### Generalized Intersection over Union (GIoU)

Das IoU-Verhältnis wird als Wert definiert, der beschreibt, inwiefern sich Flächenmengen überschneiden. Im einfachsten Fall wird ein Objekt anhand einer rechteckigen Markierung (Vorhersageraum), auch Bounding Box (BB) genannt, richtig erkannt. Eine BB entspricht der Vorhersage einer Klasse durch den Detektor in Form eines Rechtecks. Der IoU-Wert gibt wieder, in welcher Form die Größe der BB mit der tatsächlichen Größe des realen Objektraums übereinstimmt. Sowohl die Position im Raum als auch die Größe spielen eine Rolle. Dieser Wert berechnet sich wie in **Formel 2.1** angegeben. Demnach wird das Verhältnis aus der Schnittmenge zur Vereinigungsmenge zwischen dem Objekt und der vorhergesagten Position gebildet (siehe **Abbildung 2.8**). Besitzen der tatsächliche Objektraum und die BB keine Schnittmenge, lässt sich der IoU-Wert auf 0 beziffern. [Rez19]

$$IoU = \frac{A \cap B}{A \cup B} \quad \text{mit } A, B \in \mathbb{R}^n \quad (2.1)$$

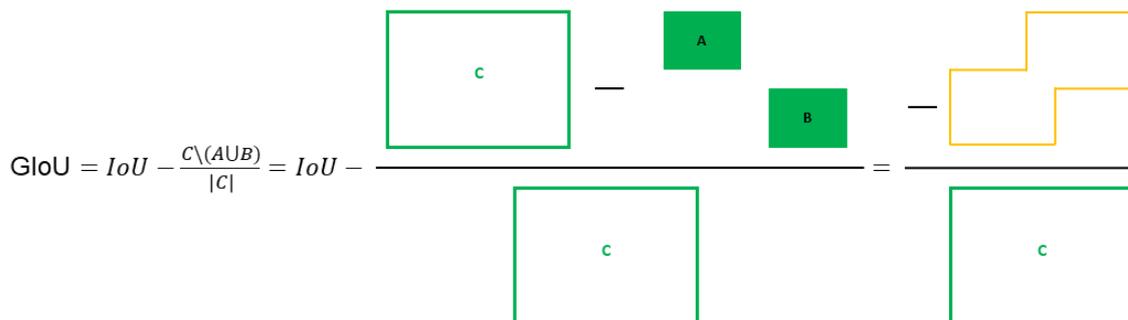


$$IoU \text{ (Überlappung der Vereinigung)} = \frac{\text{Schnittmenge}}{\text{Vereinigungsmenge}} =$$

Abbildung 2.8: Visualisierung zur Berechnung des IoU Wertes nach [Pad23]

Aus diesen Informationen lassen sich keine Daten über den Abstand zwischen BB und tatsächlichen Objektraum herleiten, wenn der IoU-Wert null beträgt. Deshalb wird dieser Wert um die Menge  $C$  erweitert, welche die kleinste  $A$  und  $B$  umfassende konvexe Form beschreibt. Dieser sogenannte GIoU-Wert wird in **Formel 2.2** definiert. In **Abbildung 2.9** ist dargestellt, wie der GIoU-Wert berechnet wird. In diesem Beispiel liegen der tatsächlicher Objektraum und die BB getrennt voneinander, sodass die Schnittmenge leer ist. Deshalb ist im letzten Rechenschritt der IoU-Wert nicht mehr vorhanden, weil dieser null beträgt. In diesem Fall ist der GIoU-Wert negativ. Dieser kann maximal den Wert minus eins annehmen. Dieser Wert stellt einen allgemeinen Kennwert für Erkennungen dar. [Rez19]

$$GIoU = IoU - \frac{|C \setminus (A \cup B)|}{|C|} \quad \text{mit } A, B \in \mathbb{R}^n \quad (2.2)$$



$$GIoU = IoU - \frac{C \setminus (A \cup B)}{|C|} = IoU -$$

Abbildung 2.9: Veranschaulichung des GIoU mit Hilfe der Mengenlehre

### Vertrauenswert der Detektion (engl. Confidence value)

Der Vertrauenswert gibt an, mit welcher Wahrscheinlichkeit eine Klasse erkannt wird und wie gut die BB das Objekt beschreibt. Es gibt zurzeit keine einheitliche Übersetzung für diese Begrifflichkeit, deshalb wird dieser innerhalb der Arbeit als Vertrauenswert der Detektion bezeichnet. Er lässt sich berechnen aus der Wahrscheinlichkeit, dass eine

vorhandene Klasse erkannt wird, multipliziert mit dem IoU-Wert (siehe **Formel 2.3**). Dieser kann Werte von null bis eins annehmen und beträgt im Standardfall 0,5.

Der Vertrauenswert gibt die Wahrscheinlichkeit der Klassifizierung und der Positionsgenauigkeit wieder und lässt sich bei verschiedenen Anwendungen der KI-Objekterkennung optional neben der Anzeige einer Klasse über der BB darstellen. Dieser Wert kann bei Klassifikationsalgorithmen wie *YOLO* (siehe Abschnitt 2.7.3) als Schwellenwert für eine Detektion festgelegt werden. Er orientiert sich an den Trainingsergebnissen. Wird dieser Wert zu niedrig eingestellt, ist die Wahrscheinlichkeit größer, dass falsch positive Ergebnisse auftreten. Je größer der Vertrauenswert als Grenze für eine Detektion gewählt wird, desto weniger Objekte werden erkannt, weil die Wahrscheinlichkeit der Klassifizierung und die Positionsgenauigkeit multipliziert einen höheren Zahlenwert annehmen müssen. Wird der Wert auf eins gesetzt, müssen die Wahrscheinlichkeit der Klassifizierung und die Positionsgenauigkeit ebenfalls den Wert eins annehmen.

$$\text{Conf.} = P(\text{Objekt}) \cdot \text{IoU} \quad (2.3)$$

### **Richtig positiv (engl. True Positive (TP))**

Im Falle des Ereignisses „richtig positiv“ stimmt eine Klassifizierung mit dem im Bild vorhandenen Objekt überein. Eine Klassifizierung wird als wahr eingestuft, wenn ein vorher festgelegter Vertrauenswert (confidence value) überschritten wird. [Faw06]

### **Falsch positiv (engl. False Positive - FP)**

Falsch positiv bedeutet, dass ein Objekt durch die Bildverarbeitung gefunden wird, das im vorliegenden Bild nicht vorhanden ist. Es handelt sich um eine Falschmarkierung. [Faw06]

### **Falsch negativ (engl. False Negative (FN))**

Das Ereignis falsch negativ trifft zu, wenn ein Merkmal im realen Bild vorhanden ist, es durch die Bildverarbeitung jedoch nicht erkannt wird. Hier wird der Vertrauenswert für das vorhandene Objekt fälschlicherweise nicht erreicht. [Faw06]

### **Richtig negativ (engl. True Negative (TN))**

Falls sich richtig negativ bewahrheitet, wird ein Merkmal, das nicht im realen Bild vorhanden ist, auch nicht durch die Objekterkennung erkannt. Es handelt sich um eine korrekte nicht-Markierung. [Faw06]

### **Verlustrate (engl. Missing Rate (MR))**

Die Verlustrate setzt sich aus den FN geteilt durch die Summe der TP und FN zusammen (siehe **Formel 2.4**). Damit beschreibt dieser Parameter das Verhältnis aus der Anzahl der Objekte, die nicht erkannt werden, zu der Gesamtanzahl der Objekte. Es handelt sich um Objekte, die nicht erkannt werden, obwohl diese tatsächlich vorhanden

sind [Faw06]. Nimmt dieser Wert zu, mehren sich die falsch negativen Erkennungen. In diesem Zusammenhang sollte der Vertrauenswert überprüft werden. [Zha20]

$$MR = \frac{FN}{(TP + FN)} \quad (2.4)$$

### **Präzision (engl. Precision (Pre))**

Die Präzision ist definiert als das Verhältnis von richtigen Detektionen zur Summe aus richtigen Detektionen und Falschdetektionen, die im tatsächlichen Bild nicht zu finden sind. Dieser Wert gibt an, wie präzise richtige Erkennungen getätigt werden (siehe **Formel 2.5**). Wenn dieser Wert abfällt, ist dies ein Hinweis darauf, dass falsch positive Detektionen vorliegen. Demnach sollte der Vertrauenswert erhöht werden.[Zha20]

$$Pre = \frac{TP}{(TP + FP)} \quad (2.5)$$

### **Recall**

Der Recall ist das Verhältnis aus richtigen Detektionen durch die Summe aus richtigen Detektionen und nicht erkannten Objekten (siehe **Formel 2.6**). Es beschreibt das Verhältnis, wie viele vorhandene Objekte erkannt werden. Befindet sich der Wert auf einem niedrigen Niveau, sollte überprüft werden, warum falsch negative Fälle existieren. Es kann ein Hinweis darauf sein, dass der Vertrauenswert zu niedrig angesetzt ist. [Zha20]

$$Rec = \frac{TP}{(TP + FN)} \quad (2.6)$$

### **Globale Genauigkeit (engl. Overall Accuracy - OA)**

Die globale Genauigkeit gibt die Genauigkeit unter Berücksichtigung aller logischen Möglichkeiten an [Zha20]. Es ist das Verhältnis aus richtigen Detektionen zu der Summe aus allen Detektionen plus die nicht erkannten Objekte (siehe **Formel 2.7**). Dieser Wert ist kleiner oder entspricht genau dem Zahlenwert der Präzision bzw. des Recalls.

$$OA = \frac{TP}{(TP + FP + FN)} \quad (2.7)$$

### **mAP-Wert**

Die durchschnittliche gemittelte Präzision (engl. mean Average Precision (mAP)) ist ein Standardwert der Objekterkennung, der aus den durchschnittlichen Präzisionen der Klassen gebildet wird (siehe **Formel 2.8**). Hierbei spiegelt  $n$  die Anzahl der Klassen und  $AP_k$  die durchschnittliche Präzision einer Klasse wider [Lz09]. Der mAP<sub>0,5</sub>-Wert gilt als Standardgenauigkeitswert der Objekterkennung, und wird mit Hilfe des IoU-

Schwellenwerts von 0,5 errechnet. Darüber hinaus gibt es den mAP<sub>0.5:0.95</sub>-Wert, welcher den Durchschnitt der mAP-Werte im Intervall von 0,5 bis 0,95 in 0,05 Schritten angibt. Wenn sich die beiden zuvor genannten Zahlenwerte deutlich voneinander unterscheiden, ist es ein Indiz dafür, dass die Präzision bei steigenden IoU-Werten abnimmt. [Bel15]

$$mAP = \frac{1}{n} \cdot \sum_n AP_k \quad (2.8)$$

## 2.6.2 OpenCV - Beispiel der Bilderkennung

*OpenCV* (Open Source Computer Vision Library) ist eine quelltextoffene Softwarebibliothek für die Bildverarbeitung und maschinelles Lernen. Maschinelles Lernen oder Machine Learning (ML) bedeutet, dass ein künstliches System aus Trainingsdaten lernt, um statistische Modelle aufzustellen, die Muster und Gesetzmäßigkeiten in den Lerndaten erfassen, sodass unbekannte Daten bewertet bzw. klassifiziert werden können [Rei15; Goo23]. Die Struktur, bestehend aus mehreren gemeinsam genutzten Bibliotheken, ist modular aufgebaut [Ope23]. Die Algorithmen in OpenCV können unter anderem dazu verwendet werden, Objekte wie Menschen, Gesichter oder Autos zu erkennen [Ope23]. Datenbanken, welche Algorithmen enthalten, sind elementar für die Bildverarbeitung und werden sowohl zum Trainieren als auch zum Testen von Klassifizierungs-, Erkennungs- und Lokalisierungsalgorithmen benutzt [Lei04].

Im weiteren Verlauf sollen vier Algorithmen vorgestellt werden, die durch *OpenCV* bereitgestellt werden. Der erste ist das Template Matching, welches auf einer Mustererkennungsstrategie beruht. In diesem Algorithmus wird die Ähnlichkeit eines Musterbilds (Template) mit Bereichen eines Suchbilds bestimmt (siehe **Abbildung 2.10**). In diesem Bild ist zu erkennen, dass die zu vergleichenden Bilder jeweils in Raster eingeteilt werden. Die Anzahl der gleichzeitig zu vergleichenden Raster ist dabei variabel. Nach und nach wird das Template mit den einzelnen Bildbereichen verglichen, bis der Algorithmus das Ende des Bildes unten rechts erreicht hat. [Ope23]

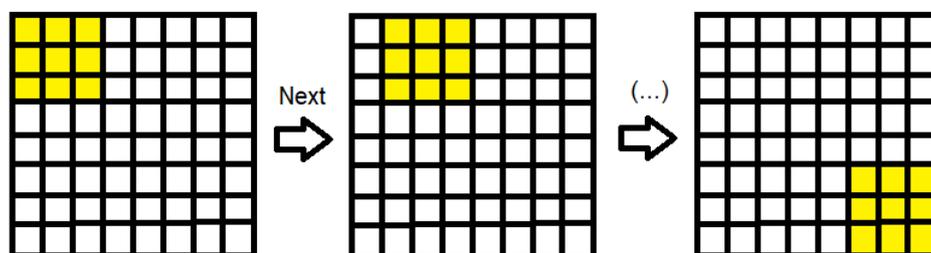


Abbildung 2.10: Erkennungsstrategie des Template Matching [BL20]

Der Template Matching-Algorithmus zeigt Limitierungen auf, wenn das Objekt im Musterbild und das Objekt im Suchbild Größenunterschiede aufweisen, Objekte im Bild

unterschiedliche Orientierungen haben und wenn Störfaktoren im Suchbild vorhanden sind, sodass Objekte nicht erkannt werden. Der Algorithmus ist ohne großen Aufwand einsetzbar und eignet sich gut für Anwendungen, in denen ein Objekt charakteristisch gut definierbar ist und die Objekte in den Suchbildern dem Muster ähnlich sind. [Has16]

Der zweite Algorithmus ist der *SIFT* (Scale-Invariant Feature Transform), der von David Lowe [Low04] entwickelt wurde. Es handelt sich um einen Bilddeskriptor, welcher wie das Template Matching Bilder miteinander abgleicht. „Der SIFT-Deskriptor ist invariant gegenüber Translationen, Rotationen und Skalierungstransformationen im Bildbereich und robust gegenüber moderaten perspektivischen Transformationen und Beleuchtungsvariationen“ [Lin12]. Dieses bedeutet, dass die Objekterkennung eine Robustheit gegenüber Drehungen oder Skalierungen eines Musters sowie Störfaktoren besitzt. Die vier grundlegenden Phasen zur Bestimmung von Merkmalen sind die Erkennung von Skalenraum-Extrema, die Lokalisierung der Keypoints (Schlüsselpunkte), die Zuweisung von Orientierungen und die Erstellung von Keypoint-Deskriptoren [Low04].

Der dritte Algorithmus heißt *SURF* (Speeded-Up Robust Features). Dieser ist eine Weiterentwicklung des *SIFT*-Algorithmus und nutzt Schlüsselpunkte in einem Bild zum effizienten Detektieren. Anschließend werden Gaußfilter zur Glättung eingesetzt, sodass Objekte besser erkannt werden. Es gibt verschiedene Versionen des *SIFT*-Algorithmus, die mit unterschiedlichen Bildauflösungen arbeiten, wodurch Auswirkungen auf die Rechenleistung- bzw. die Rechenzeit und die Erkennungsgenauigkeit entstehen. [Bay06]

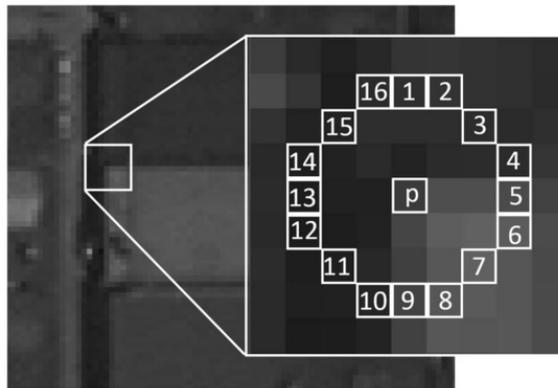


Abbildung 2.11: Ermittlung eines Schlüsselpunktes durch den FAST-Keypoint-Detektor [Hua18]

Der vierte Algorithmus ist der ORB (Oriented FAST and rotated BRIEF) Algorithmus, welcher auf dem FAST-Keypoint-Detektor und einer modifizierten Version des visuellen Deskriptors BRIEF (Binary Robust Independent Elementary Features) basiert [Rub11]. Die Schlüsselpunkte werden durch den Fast-Keypoint-Detektor gefunden, indem die Helligkeit eines Pixels mit den 16 umliegenden Pixel verglichen und in drei Klassen aufgeteilt wird: heller, dunkler oder ähnlich hell wie der Ausgangspixel (siehe **Abbil-**

**dung 2.11**). Ab einem Schwellenwert, z.B. acht Pixel sind heller oder dunkler als der betrachtete Pixel  $p$ , wird ein Schlüsselpunkt gesetzt [Rub11]. Da der FAST-Keypoint-Detektor nicht skaleninvariant ist und keine Orientierungskomponente enthält, wird eine mehrskalige Bildpyramide erstellt, die ein Bild in verschiedenen Skalierungen bzw. Auflösungen enthält (siehe **Abbildung 2.12**). Durch die Erstellung von Keypoints in verschiedenen Ebenen der Pyramide wird eine Skaleninvarianz erreicht [Rub11].

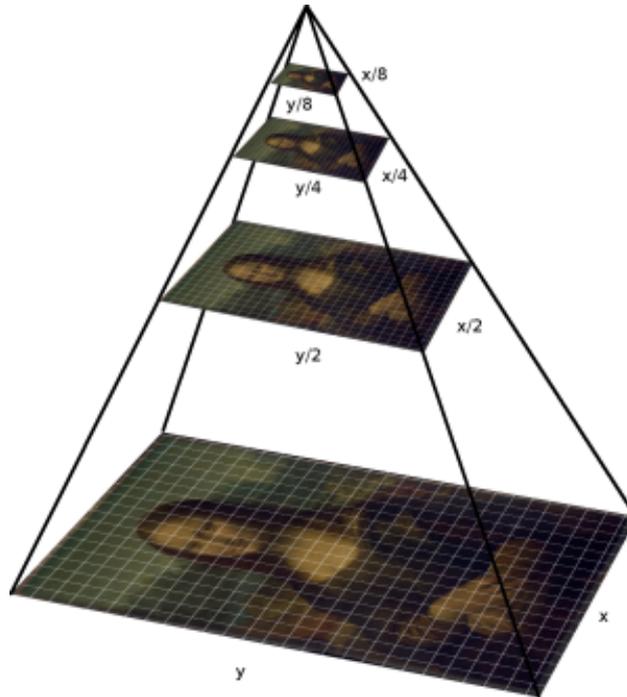


Abbildung 2.12: Bildpyramide als Multiskalendarstellung eines Bildes [Tya19]

Der BRIEF-Deskriptor ist eine Bitstring-Beschreibung eines Bildfeldes. Diese Beschreibung wird aus einer Reihe von binären Intensitätstests zusammengestellt [Rub11]. Die ermittelten Schlüsselpunkte werden in einen binären Merkmalsvektor umgewandelt, welcher aus einer bis zu 512 Bit langen Zeichenkette besteht [Rub11]. Durch die Beschreibung als Vektor können Rechenoperationen effizienter arbeiten, weshalb der Algorithmus zu einem schnellen und robusten Detektor zählt und sich gut für die Erkennung lokaler Merkmale eignet [Rub11]. Der *ORB*-Algorithmus ist im Gegensatz zum *SIFT*- und *SURF*-Algorithmus nicht patentiert [Tya19; Ope22].

Lukman und Yang haben die soeben vorgestellten Algorithmen gegenübergestellt und kamen zu dem Ergebnis, dass Genauigkeiten (OA) bei der Objekterkennung im Durchschnitt von etwa 0,5 bis 0,8 erreicht werden konnten. Beim Testen der Robustheit, z.B. durch die Drehung der zu erkennenden Objekte, nahmen die Erkennungsgenauigkeiten erheblich ab. Je nach Objekt nehmen die Genauigkeiten ab und erreichen teilweise nicht die 5% Marke. Die Erkennungsgenauigkeit (OA) in Bezug auf andere Früchte, bei denen eine Drehung keinen so signifikanten Einfluss hat, betrug 0,3 bis 0,5. Die

richtig-positiv-Rate erreichte bis zu 80%, während die falsch-positiv-Rate im besten Fall 1,45% betrug. [BK21]

## 2.7 Künstliche Intelligenz (KI)

In diesem Unterkapitel wird die Thematik KI diskutiert und der Stand im Hinblick auf die Bilderkennung dargelegt. Der Begriff Künstliche Intelligenz (engl. Artificial Intelligence - AI) wird definiert als eine intelligente Verhaltensweise von Computerprogrammen oder Maschinen, wobei die Handlung dem Vorbild eines intelligenten Menschen gleichzusetzen sei [Fla16]. Diese Definition hat die Schwachstelle, dass Intelligenz nur sehr schwer zu beschreiben ist und es keine einheitliche Definition dazu gebe. Einige Autoren versuchen den Begriff mit Fähigkeiten zu umschreiben, dass in Situationen, in denen wenige und/oder widersprüchliche Informationen vorliegen, ein Lösungsweg kreiert werden kann, wobei auf vergangene Erfahrungen (Machine Learning) zurückgegriffen werden kann. Es ist die Rede von einer Verarbeitung von kognitiven Prozessen, die gleichzeitig verarbeitet werden können und, dass für die Situation beste Ergebnis eruiert werden kann. [Kap17; Lun16; SA21; Zur92; NE22]

KI gewinnt immer mehr an Bedeutung. Laut dem Bericht des *BMWK* sahen im Jahr 2019 die Unternehmen die Bedeutung des KI-Einsatzes zu 68% bis 85% in den verschiedenen Branchen als wichtig oder essentiell an [Bun19]. *Lunze* nennt die folgenden Punkte als Teilgebiete der KI-Forschung [Lun10]:

1. Problemlösen und maschinelles Beweisen,
2. Spracherkennung und Verstehen natürlicher Sprache,
3. Bildverarbeitung und Bilderkennung,
4. Lernen,
5. Expertensysteme,
6. Qualitatives Schließen,
7. Intelligente Roboter,
8. KI-Hardware und KI-Software.

*Kaplan* nennt in diesem Kontext den Ingenieurberuf als einen der am schwierigsten zu automatisierenden Berufe [Kap17]. Ingenieurtechnische Anwendungen der KI sind [Lun16]:

- Entwurfsaufgaben,
- Analyse- und Überwachungsaufgaben,

- Planung und Steuerung in der offenen Wirkungskette,
- Steuerung im geschlossenen Wirkungskreis.

### 2.7.1 Neuronales Netz (NN)

Das Vorbild der Nachahmung des intelligenten Verhaltens eines Menschen findet sich auch im Aufbau der KI wieder. Die kognitive Simulation ist einer der frühesten Ansätze der Künstlichen Intelligenz [Fla16]. Der Aufbau einer KI ähnelt vereinfacht einer Abstraktion eines menschlichen Gehirns. Die Kommunikation zwischen Neuronen erfolgt beim Menschen durch die Übertragung von elektrischen oder chemischen Signalen mit Hilfe von Synapsen. Eingangssignale werden mit synaptischen Gewichten multipliziert, woraus sich eine Ergebnisfunktion zusammensetzt. Das Aktionspotential ist ein Grenzwert, welches für die weitere Signalverarbeitung überschritten werden muss. Wird es überschritten, wird bspw. ein Signal an die nächste Schicht weitergegeben. Dementsprechend setzt sich das künstliche Neuronale Netz (NN) aus den Summen der Funktionen und Gewichtungen zusammen (siehe **Abbildung 2.13**). Sind alle Neuronen mit den Neuronen der davor- und dahinterliegenden Schicht verbunden, wird von einem „dichten (dense) NN“ gesprochen [Fro18]. Beim Anlernen der KI wird das NN bzw. die Verknüpfungen in Form der Gewichtungen angepasst, sodass für den trainierten Anwendungsfall ein einzigartiges NN entsteht. Bei Verwendung eines Bildes als Eingangsgröße nehmen die Elemente der Eingabeschicht den Wert eines Pixels an. Nach Verarbeitung der Signale werden die Ausgangssignale  $\bar{Y}_n$  in der Ausgabeschicht berechnet. Bei der Klassifikation wird genau ein Neuron der Ausgabeschicht aktiviert.

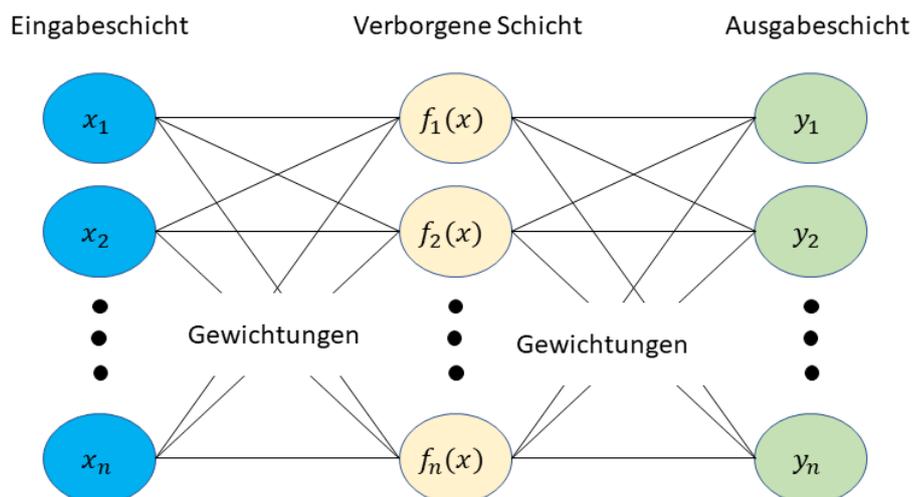


Abbildung 2.13: Aufbau eines neuronalen Netzes nach [Fla16]

Convolutional Neural Networks (CNN – gefaltete neuronale Netze) sind besondere Formen der NN. Durch die Einteilung in Gitterstrukturen eignen Sie sich besonders für

die Verarbeitung von Bildern. Eine Faltung ist die Summe gewichteter Werte bzw. Funktionen, deren Ergebnis eine Feature Map (FM) ist. Ein Kernel  $K$  entspricht einer Matrix, die eine Faltung widerspiegelt. Er kann als Gewichtung des NN interpretiert werden. Ein Element der Eingangsmatrix wird als Input  $I$  bezeichnet. Durch die Multiplikation des Inputs  $I$  mit dem Kernel erhält man eine neue Matrix. Dieser Prozess wird als Faltung bezeichnet. Der Kernel kann in Bezug auf die klassische Bildverarbeitung als Filter interpretiert werden. In der Regel wird auf eine zwei- oder dreidimensionale Matrix ein Kernel in Form einer kleineren Matrix angewendet, indem die Matrixmultiplikation eine neue Matrix ergibt. [Fro18]

### 2.7.2 Training der KI - Lernen (Deep Learning/ Machine Learning)

Das Lernen, in dem das NN angepasst wird, ist ein wichtiger Bestandteil der KI-Systeme. Beim Maschinellen Lernen (ML) werden Daten insofern angelernt, als dass eine Modellanpassung für den Anwendungsfall stattfindet. Beispielsweise kann ein Modell des Energieverbrauchs einer Produktionslinie erlernt werden [NE22]. Grundsätzlich wird zwischen überwachtem Lernen (engl. supervised learning), bestärkendem Lernen (engl. reinforced learning), welches hier nicht betrachtet wird, und unüberwachtem Lernen (unsupervised learning) unterschieden. Für das überwachte Lernen müssen Daten generiert werden, welche die KI zum „auswendig“ Lernen nutzt. Ein Anwendungsbeispiel ist die Bilderkennung, bei der spezielle Objekte bzw. Klassen in Bildern gelabelt, also die Position und Größe anhand des tatsächlichen Objektraumes vorgegeben werden, und diese aufbereiteten Daten dann zum Trainieren an die KI übergeben werden. Demgegenüber werden beim unüberwachten Lernen die Trainingsdaten nicht vorab klassifiziert. [CC08]

Für das Lernen gibt es Datenbanken, die gelabelte Trainingsdaten für das überwachte Lernen bereitstellen. Der ImageNet-Datensatz [Rus15] und der COCO-Datensatz von Microsoft [Lin14] enthalten zusammen viele Trainingsdaten mit alltäglichen Klassen wie Menschen und Autos. COCO ist dabei ein Open-Source-Datensatz zur groß angelegten Objekterkennung, -segmentierung und -beschriftung einschließlich Label [COC23]. Das Problem dabei ist, dass der Datensatz nur für spezifische Trainingsanwendungen verwendet werden kann, da nur bestimmte Klassen im Datensatz enthalten sind. Folglich können die Datenbanken nur für eine begrenzte Anzahl an Anwendungen genutzt werden. Kann eine solche Datenbank genutzt werden, erleichtert dies das Lernen deutlich, weil zum Trainieren der KI i. d. R. mehrere tausend gelabelte Trainingsdaten notwendig sind, um ein Modell hinreichend genau erstellen zu können.

Beim Lernen können mehrere Ursachen dazu führen, dass die Qualität eines Modells negativ beeinflusst wird. Als erstes ist das „overfitting“ zu nennen, bei dem das KI

Modell nur in Verbindung mit den bekannten Daten korrekte Ergebnisse liefert. In anderen Kontexten werden die trainierten Merkmale nicht mehr erkannt. Auf der anderen Seite führt „underfitting“ dazu, dass ein Datenmodell nicht in der Lage ist, die Beziehung zwischen den Eingabe- und Ausgabevariablen genau zu erfassen, wenn ein Modell zu wenig Einflussgrößen hat. Dies resultiert in einer hohen Fehlerquote sowohl bei der Trainingsmenge als auch bei den ungesehenen Daten. [Yin19; Aal08]

### 2.7.3 YOLO (You Only Look Once)

*YOLO* ist ein Objekterkennungssystem, das mit einer Vielzahl von Deep-Learning Frameworks verwendet werden kann, darunter Darknet, Tensorflow, pytorch und andere. Es kann in Echtzeit detektieren und wird auch in der Automobilbranche verwendet. Dahingegen ist *OpenCV* eine Bildverarbeitungsbibliothek, die eine Reihe von Werkzeugen und Algorithmen für die Bild- und Videobearbeitung, einschließlich Objekterkennung, bereitstellt (siehe Abschnitt 2.6.2). *OpenCV* enthält keine *YOLO*-Implementierung in seiner Kernbibliothek, aber es bietet Schnittstellen zur Verwendung von *YOLO* durch das Modul Deep Neural Network (DNN) an. [Cha18]

Andere Ansätze wie R-CNN, ein zweistufiger Objekterkennungsalgorithmus, verwenden Methoden zur Festlegung von Regions of Interest, um den Fokus auf interessante Bildbereiche zu legen und im Anschluss eine Klassifizierung vornehmen. Der komplette Prozess der Objekterkennung wird zu einem einzigen Regressionsproblem zusammengefasst. *YOLO* kann durch die Betrachtung des originalen Bildes ohne das Festlegen von ROIs direkt von den Bildpixel auf die BB bzw. Position der Klassen schließen. [Red15]

Beim ersten Schritt des *YOLO*-Algorithmus wird die Größe des Bildes an die Inputeinstellungen des neuronalen Netzes angepasst (resizing). Nach dem Input wird das NN durchlaufen und alle Werte werden berechnet. Wird ein Schwellenwert (confidence value) an der Ausgabeschicht überschritten, wird eine Klassifizierung vorgenommen und eine BB mit der entsprechenden Klasse ausgegeben (siehe **Abbildung 2.14**). Der Vertrauenswert kann als Wert interpretiert werden, wie wahrscheinlich es ist, dass eine Klasse erkannt wird. Dies ist neben dem Klassennamen oberhalb des erkannten Objektes in **Abbildung 2.14** links daneben zu sehen. In der zuletzt genannten **Abbildung** werden drei Objekte erkannt. Die Kategorie Mensch wird mit einem Vertrauenswert von 0,64 detektiert. Dahingegen wird ein Hund mit einer Wahrscheinlichkeit von 0,3 und ein Pferd mit einer Wahrscheinlichkeit von 0,28 erkannt. Es ist zu sehen, dass die angegebenen Rechtecke das Objekt nicht gänzlich umschließen. Das bedeutet, dass der GIoU-Wert das Optimum nicht erreicht.

Außerdem ist in **Abbildung 2.14** gezeigt, wie der *YOLO*-Algorithmus grundsätzlich funktioniert. Zunächst wird das Bild in der Inputschicht aufgenommen und die Bildgröße

und -auflösung wird verändert. Danach erfolgt die Berechnung der Matrizen für das gefaltete NN (CNN). CNN werden häufig in der Bild- und Audioverarbeitung eingesetzt. Der in Abbildung 2.14 erwähnte non-max suppression-Algorithmus ist eine Technik, die bei zahlreichen Bildverarbeitungsoperationen eingesetzt wird. Dieser führt eine Plausibilitätsprüfung von Mehrfachdetektionen (Überlappungen) eines identischen Objektes in der Ausgabe durch, um Mehrfacherkennungen für ein Objekt herauszufiltern. Dafür wird die Umgebung nach erkannten Klassen analysiert. [Mru20].

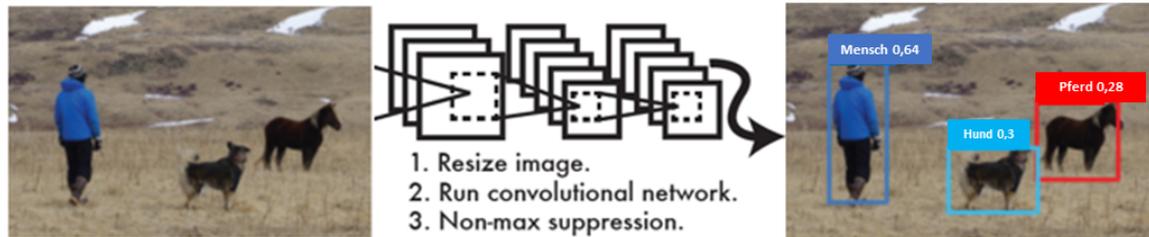


Abbildung 2.14: Ablauf des *YOLO*-Algorithmus nach [Red15]

Nach der Klassifikation wird ein Vektor mit fünf Einträgen ( $x$ ,  $y$ ,  $w$ ,  $h$  und Klasse) ausgegeben, der die Position, Breite und Höhe (insgesamt die BB) des erkannten Objektes inklusive der Klasse ausgibt. Eine Klasse ist ein definiertes Objekt, wie z. B. ein Mensch, welches durch die Detektion erkannt werden soll. [Red15]

Über die Zeit wird *YOLO* stetig weiterentwickelt, sodass mehrere Versionen vorhanden sind. Innerhalb dieser Arbeit wird die Version 4 von *YOLO* verwendet. *YOLO* zählt zu den genauesten und schnellsten Objektdetektionsalgorithmen (ODA). Dadurch, dass einstufige Detektoren nur einen Detektionsschritt besitzen, sind diese schneller, erreichen also mehr Frames per Second (FPS) und sind dadurch für die Echtzeitdetektion verwendbar (siehe **Abbildung 2.15**) [Boc20]. Dies kann bspw. beim autonomen Fahren wichtig sein, wenn sich ein Auto mit hoher Geschwindigkeit bewegt und auf Hindernisse schnell reagiert werden muss. Hier wird in der Abbildung 2.15 von einer „Dense Prediction“ gesprochen, weil die Detektion 1:1 mit den Koordinaten des vorhandenen Bildes übereinstimmt. Werden bei dem zweistufigen Detektor Interessensregionen festgelegt und nochmals untersucht, müssen diese Bildausschnittskoordindaten wieder zurück in das ursprüngliche Koordinatensystem zurücktransformiert werden. Deshalb wird dies „Sparse Prediction“ genannt. [Dao22; Wan20; Wan21]

In den einzelnen gefalteten Schichten befinden sich weitere Blöcke mit enthaltenen Optimierungsalgorithmen zur Reduktion der durchzuführenden Rechenoperationen, worauf in dieser Arbeit nicht eingegangen wird, weil es für den weiteren Verlauf nicht zielführend ist. *Scaled YOLOv4* nutzt die Data Augmentation, eine künstliche Erzeugung von Daten, um die Datenmenge zu erhöhen, damit die Objekterkennung robuster gestaltet und die Effizienz erhöht wird. Es werden außerdem die Helligkeits-, Kontrast-,

Sättigungs- und Rauschwerte (fotometrische Parameter) im Bild variiert. Darüber hinaus werden geometrische Änderungen in Form von Drehungen, Skalierungs-, Größen- und Pixelabstandsänderungen vorgenommen. Diese Veränderungen des Ausgangsbildes finden auf Pixelebene statt. Eine weitere Technik (CutMix) schneidet einen rechteckigen Bildausschnitt aus und fügt diesen in ein anderes Bild ein. Dadurch wird die Genauigkeit des Modells erhöht und die Objekterkennung verbessert sich bezüglich Bilddaten, die in einem fremden Kontext auftreten, also nicht im Trainingsdatensatz erhalten sind. Zuletzt vereint die Mosaic Data Augmentation vier Trainingsbilder zu einem neuen Bild, wodurch die vorhandenen Klassen in neue Kontexte gesetzt werden. [Boc20]

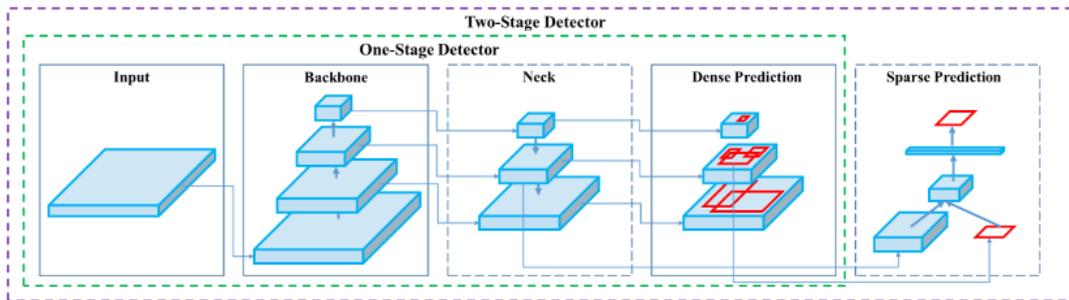


Abbildung 2.15: Unterschied zwischen einstufigen und zweistufigen Detektoren [Boc20]

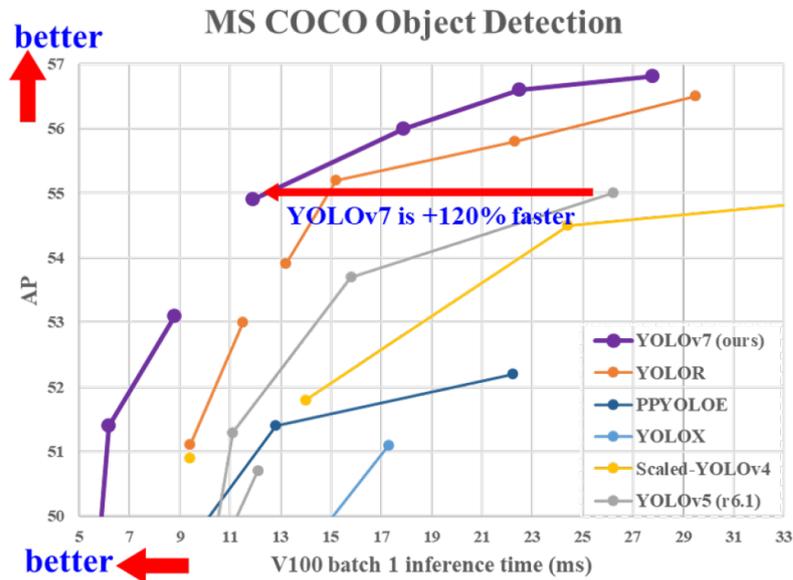


Abbildung 2.16: Performancevergleich zwischen den YOLO-Versionen [Wan22]

Zurzeit sind die YOLO Versionen 7 und 8 aktuell erschienen. Der Graph in **Abbildung 2.16** zeigt den Leistungsunterschied der verschiedenen YOLO-Versionen. Es werden jeweils die Standardbibliotheken von MS COCO für das Training verwendet. Auf der Abzisse ist die Reaktionszeit aufgetragen, während auf der Ordinate die Genauigkeit (AP) aufgetragen ist. Es ist abzulesen, dass die neueren YOLO-Versionen schneller

sind und eine höhere Präzision von bis zu 6% aufweisen. Andere Veröffentlichungen vergleichen die Anzahl benötigter Trainingsdaten und FLOPs (Floating Point Operations). FLOPs ist eine Kennzahl, die beschreibt, wie viele Gleitkommazahl-Operationen pro Sekunde durchgeführt werden [Wha22]. Hier zeigt sich, dass *YOLOv7* im Vergleich zu *YOLOv4* 75% weniger Parameter und 36% weniger Rechenoperationen bei einer um 1,5% erhöhten durchschnittlichen Genauigkeit erreicht. [Wan22]

Da die Version acht von *YOLO* erst kürzlich erschienen ist, sind hier wenig Informationen zur Leistung vorhanden. Es gibt einen Graphen, der auf GitHub veröffentlicht ist (siehe **Abbildung 2.17**). Hier zeigt sich, dass die neue Version mit noch weniger Parametern bei besseren mAP-Werten auskommt. Außerdem ist die Erkennungsgeschwindigkeit leicht erhöht. Allerdings soll sich die Klassifikationsgüte in Bezug auf große Modelle (im Vergleich zu *YOLOv5*) nicht verbessert haben [Mal23]. Demnach würde sich der Umstieg auf die neueren Versionen nur lohnen, wenn kleine Modelle verwendet werden, falls die Schnelligkeit der Detektion wichtig ist. Die AP verbessert sich hingegen marginal.

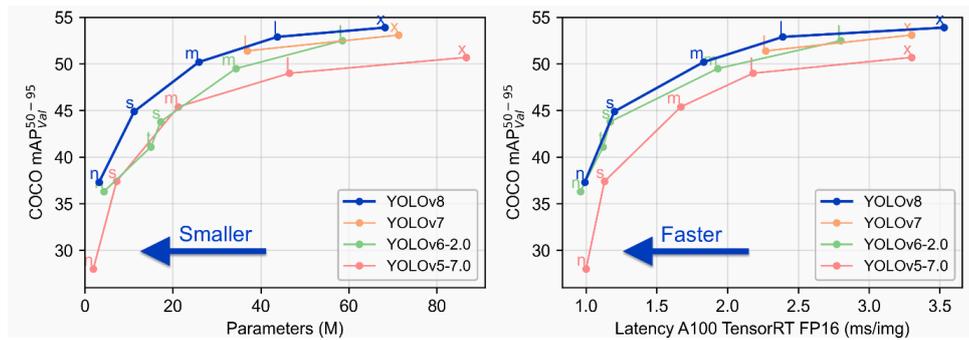


Abbildung 2.17: Leistungsvergleich zwischen *YOLOv7* und *YOLOv8* [Joc23]

## 2.8 Bilderkennung in Bezug auf technische Zeichnungen

In diesem Unterkapitel wird der Stand der Technik der KI in Bezug auf TZ näher behandelt. Wie in Unterkapitel 2.1 beschrieben, sind TZ ein wichtiges Verständigungsmittel und weisen aufgrund Ihrer detailreichen Darstellungen eine hohe Komplexität auf. Erste wenige Arbeiten zu dem Thema Bilderkennung in TZ (mit Hilfe der KI) sind vorhanden und werden hier vorgestellt.

Zunächst gibt es Ansätze, die versuchen, Texte und Zahlen, wie z.B. Bemaßungen und Toleranzen, aus den TZ zu extrahieren. Die Firma *Werk24* liest Schriftfelder, Bemaßungen, sowie Form- und Lagetoleranzen aus und versucht diese zu deuten [W2421]. Die Extraktion von Buchstaben und Ziffern wie z.B. Toleranzsymbolen geschieht auf Basis von OCR (Optical character recognition). Mit Hilfe des Cloud-basierten Bildanalyse-Systems von Google Vision ist es gelungen, Informationen aus einer TZ zu ziehen (siehe **Abbildung 2.18**). Es ist jedoch zu erkennen, dass die Objekterkennung bei

einigen Symbolen Ungenauigkeiten aufweist, weil bspw. Durchmesserzeichen teilweise als null erkannt werden. Einen ähnlichen Einsatz verfolgt die Firma *Elias*, die aus TZ automatisch Prüfpläne für die Erstbemusterung oder die statistische Prozesskontrolle erstellt [ELI23]. Aus 2D-CAD, PDF- oder TIF-Formaten sollen automatisiert Prüfpläne angefertigt werden, die aus den Schriftfeldern der TZ entnommen werden. Genaue Informationen zur verwendeten Methode oder von genutzten Bibliotheken werden nicht benannt. Das Angebot zielt auf eine kommerzielle Nutzung der KI ab.

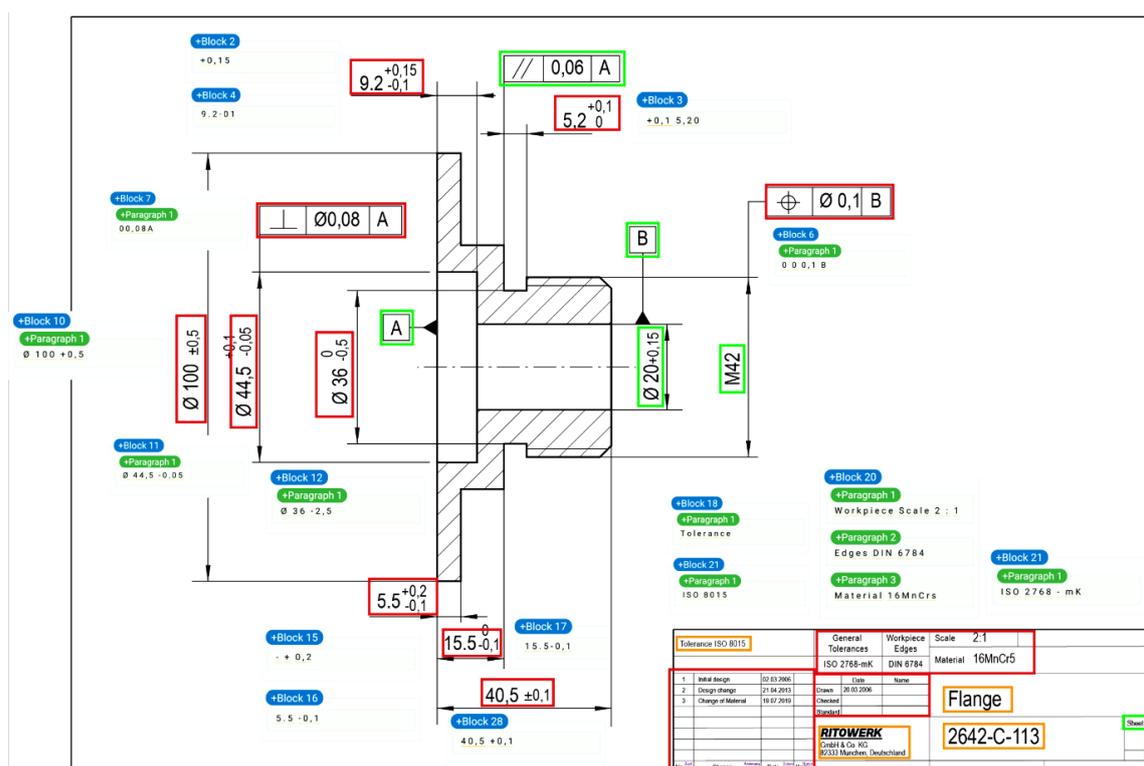


Abbildung 2.18: KI-Bildererkennung einer TZ mittels Google-Vision [W2421]

Eine andere Herangehensweise hat die französische Agentur für Verteidigungsinnovation (French Defense Innovation Agency) zusammen mit der Firma Spare Parts 3D und der Universität für Forschung in automatisierter Produktion (*LURPA*) an der *École Normale Supérieure (ENS) Paris-Sarclay* verfolgt. Innerhalb des auf drei Jahre ausgelegten Projektes mit dem Namen *RAPID* soll eine Softwarelösung entwickelt werden, die aus technischen 2D-Zeichnungen in Kombination mit einer Schriftanalyse automatisch 3D-Modelle ableiten kann. Damit ist es möglich, die Additive Fertigung direkt anzustoßen, ohne dass eine Person für diesen Prozesszwischenschritt benötigt wird. Bisher sind jedoch noch keine wissenschaftlichen Ergebnisse veröffentlicht worden, da das Projekt im Jahr 2022 gestartet ist. [3Dr22; Kre22]

*Elyan et al.* haben einen Detektionsalgorithmus genutzt, um Symbole (Sensoren, Ventile etc.) in Schaltplänen (Piping and Instrumentation Diagram) zu erkennen. Die Symbole sind in ihrer Art und Form vergleichbar mit der Darstellung von Maschinenelementen in

TZ (siehe **Abbildung 2.19**). Der *YOLO*-Algorithmus wird von den Autoren verwendet, da Bounding-Box anhand von Koordinaten und Klassenwahrscheinlichkeiten ausgegeben werden und eine Detektion schnell abläuft. [Ely20] Ähnliche Ergebnisse zu dem zuvor genannten Thema der Autoren *Elyan et al.* zeigten sich bei *Dzhusupova et al.* [Dzh22].

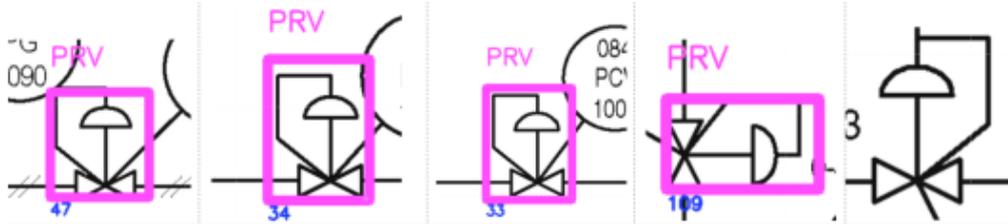


Abbildung 2.19: Erkennung von Sicherheitsablassventilen in Hydraulikschaltplänen [Ely20]

Forscher der *Shanghai Jiao Tong University* haben die Objekterkennung auf Strukturzeichnungen (Baupläne) untersucht. Mit Hilfe von *YOLO* werden Komponenten in einer 2D-Zeichnung erkannt und analysiert. Informationen zur Position und Größe der Klassen konnten extrahiert werden. Bei den Komponenten handelt es sich um Träger, Balken und Säulen. Es werden Trainingsdatensätze mit einer Anzahl von 400 bzw. 1200 Bildern verwendet. Die Präzision der Objekterkennung lag demnach bei 0,7 bis 0,95, wobei die Lokalisationsgenauigkeit bei 10% liegt. Die Autoren schlussfolgern, dass es Limitationen bei der Bestimmung der Lage und Anordnung und der Interpretation der Funktion im Gesamtsystem gebe. [Zha20]

Ein weiterer Versuch wurde von *Firas* unternommen, um einen Objekterkennungsalgorithmus für die Analyse technischer Zeichnungen zu verwenden. In dieser Arbeit werden *YOLO*, *RetinaNet* und *SSD* (Single Shot Detector) verwendet und miteinander verglichen. Hauptsächlich werden die Toleranz- und Bemaßungsangaben aus Zeichnungen entnommen. Dabei werden mAP-Werte von 0,7947 (*RetinaNet*), 0,5821 (*YOLO*) und 0,2633 (*SSD*) erreicht. *RetinaNet* ist ein einstufiger Objekterkennungsalgorithmus, welcher für kleine und eng gepackte Objekte angewendet wird. Aus diesem Grund hat es sich zu einem beliebten Objekterkennungsmodell für Luft- und Satellitenbilder entwickelt [Ale18; Lin17; Lin17]. Eine umfassende Untersuchung, in der die Daten genauer analysiert werden, hat nicht stattgefunden. [Fir20]

Der *YOLO*-Detektionsalgorithmus wird in einer weiteren Veröffentlichung von *Müller et al.* verwendet, um die gießgerechte Gestaltung zu analysieren. Dabei lag das Hauptaugenmerk auf der Erkennung von konstruktiven Gestaltungsfehlern. [Mü20]

## 3 Vorgehen der Arbeit

Nachdem im Stand der Technik relevante Begriffe und Methoden, wie TZ, KI, Bildverarbeitung, Machine Learning (Maschinelles Lernen), Konzepte zur Kompetenzbewertung usw., vorgestellt wurden und die Anwendung der KI in Bezug auf TZ dargelegt wurde, ergibt sich hier eine Forschungslücke. Der Bedarf einer KI-Objekterkennung besteht nicht nur für die Lehre sondern auch für die Industrie. Anhand des Bedarfes wird das Ziel der Entwicklung einer KI-Objekterkennung für Bauteile in TZ formuliert. Um diese Forschungsfragen näher zu untersuchen, ist diese Arbeit in die folgenden Kapitel untergliedert, wobei das grundsätzliche Vorgehen der **Abbildung 3.1** entnommen werden kann. In Kapitel 4 wird die Entwicklung der Objekterkennung für TZ beschrie-

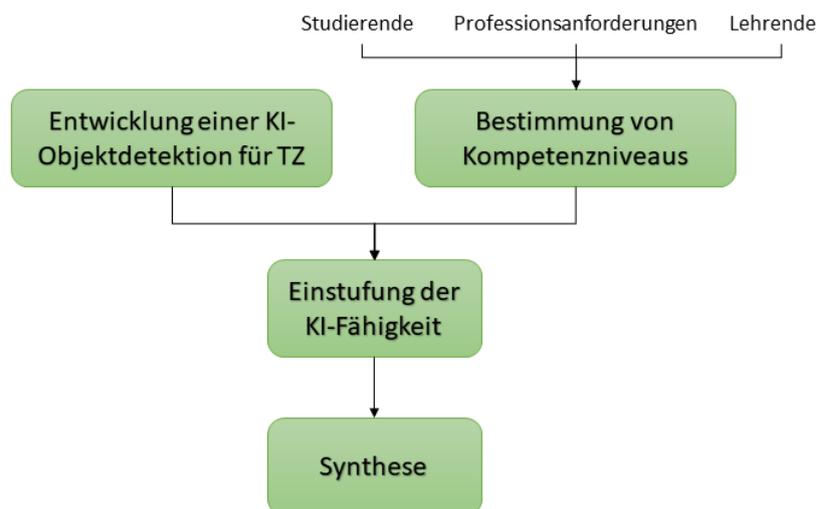


Abbildung 3.1: Vorgehen der Dissertation zur Bestimmung des KI-Niveaus

ben. Zunächst werden Vorversuche durchgeführt, um den Einfluss der verschiedenen Parameter zu bestimmen und eine Priorisierung zur Optimierung vorzunehmen, damit das Ziel der Optimierung der Erkennungsgenauigkeit effektiv erreicht werden kann.

Aufgrund der geringen Anzahl an vorliegenden Trainingsdaten wird eine Möglichkeit der digitalen Datengenerierung untersucht. Ein Wellengenerator, welcher automatisiert technische Getriebezeichnungen erstellt, wird entwickelt. Der Algorithmus fügt automatisch die für das Training der KI benötigten Label hinzu. Anhand von drei Modellen wird die Qualität der synthetisch erstellten Trainingsdaten geprüft. Es werden ein KI-Detektionsmodell, welches ausschließlich mit synthetischen Bildern trainiert wird, ein manuelles Modell, welches ausschließlich mit realen TZ angelernt wird, sowie ein gemischtes Modell, welches sowohl mit synthetischen als auch mit realen Bilddaten trainiert wird, erstellt.

Anschließend wird das beste der drei getesteten Modelle verwendet, um eine Parameteroptimierung durchzuführen. Die in den Vorversuchen als signifikant herausgestellten Parameter werden mit Hilfe eines teil-faktoriellen Versuchsplans variiert. Es existieren zwei Ansatzpunkte für die Parametervariation. Auf der einen Seite können verschiedene Parameter im Training angepasst werden und auf der anderen Seite können Werte während der Detektion konfiguriert werden. Das Ergebnis dieses Kapitels ist ein optimiertes KI-Detektionsmodell, welches in der Lage ist, Bauteile in TZ zu erkennen. Abschließend wird eine Analyse durchgeführt, um die Zuverlässigkeit der Detektion zu bewerten. In diesem Abschnitt wird auch eine Gegenüberstellung zu anderen Objekterkennungsmethoden präsentiert.

Danach werden in Kapitel 5 die Anforderungen an den Ingenieur bzw. die Ingenieurin in Bezug auf das Modul Technisches Zeichnen gesammelt und analysiert. Damit können verschiedene Kompetenzstufen definiert werden, um die Fähigkeit der KI später begründet einstufen und mit den menschlichen Fähigkeiten (Studierende) vergleichen zu können. Um alle Anforderungen des Moduls Technisches Zeichnen berücksichtigen zu können, werden NRW-weit die Modulhandbücher der Hochschulen analysiert, die Lehrenden und Studierenden befragt, die Bedingungen zur Erstellung von öffentlichem Bildungsmaterial gesammelt und didaktische Anforderungen eruiert. Mit diesen Informationen können Bewertungsskalen aufgestellt werden, um die Fähigkeiten allgemein zu bewerten. Außerdem werden die gesammelten Themen, welche innerhalb des Moduls Technisches Zeichnen gelehrt werden, genutzt, um Ansatzpunkte für die Nutzung der KI herauszustellen und damit potentielle Lernszenarien beispielhaft darstellen zu können.

Nach der Definition der Kompetenzstufen wird die Detektion genutzt, um die Objekterkennung in der Lehre zu verwenden. Es wird eine Lernsoftware für angehende Ingenieure bzw. Ingenieurinnen entwickelt, welches das Erlernen der Themen des Moduls Technisches Zeichnens erleichtern soll (siehe Kapitel 6). Die Software soll Studierende beim Lesen technischer Zeichnungen unterstützen. Anhand der entwickelten Grundfunktionen kann die Software für weitere Lehrveranstaltungen und Anwendungen genutzt werden. Eine Weiterentwicklung für verschiedene Problemstellungen ist anhand des Standes der Technik möglich, indem beispielsweise Spielkonzepte damit verknüpft werden. Es wird ein Konzept erarbeitet, wie es in die Lehre integriert werden kann und inwiefern es mit anderen Lehrkonzepten wie zum Beispiel dem Blended Learning kombinierbar ist. Die Integration in andere Lehrszenarien und den Berufsalltag wird diskutiert.

Abschließend wird das Niveau der KI in Bezug auf das Technische Zeichnen in Kapitel 7 bewertet und mit dem durchschnittlichen menschlichen Können der Studierenden verglichen. Es wird analysiert, inwiefern die KI als eine sinnvolle Unterstützung in der beruflichen Ausbildung (Studium) sowie im Berufsalltag agieren kann. Außerdem wird eruiert, ob das Tool in Verbindung mit *ChatGPT* als öffentliches Lehr-/Lernmaterial

(OER) bspw. in einem Massive Open Online Course (MOOC) für Lernende weltweit zur Verfügung gestellt werden kann.

Im achten und letzten Kapitel wird ein Ausblick darüber gegeben, wo die KI als Werkzeug konkret eingesetzt werden kann und welche Optimierungen am KI-Modell noch ausgearbeitet werden können. Außerdem werden der Punkt der öffentlichen Zugänglichkeit der KI und die dafür erforderlichen Schritte diskutiert.

## 4 Entwicklung einer KI-gestützten Objekterkennung für technische Zeichnungen

Es wird im Folgenden eine KI-Objektdetektion entwickelt, welche Maschinenelemente in TZ erkennen soll. Die Entwicklung gliedert sich in drei Schritte. Zunächst steht das Training der KI im Fokus, in der das NN an die Applikation angepasst wird. Danach wird die Detektion des KI-Algorithmus getestet, die Daten statistisch ausgewertet und das Modell optimiert. Abschließend wird bewertet, inwiefern eine KI-Objektdetektion in der Lage ist, Bauteile innerhalb von TZ zu erkennen.

Für den vorliegenden Fall wird der KI-Detektionsalgorithmus *YOLOv4* ausgewählt, weil dieser laut dem Stand der Technik eine gute Möglichkeit darstellt, Maschinenelemente bzw. die dafür verwendeten Symbole in TZ erkennen zu können. Da das Erstellen eines KI-Modells inklusive Training ein langwieriger Prozess ist, wurde beim Start der Arbeit das aktuellste Modell *YOLOv4* verwendet. Ein Wechsel auf eine neue Version stellt einen erhöhten Aufwand dar. Es wird Abstand von einem zweistufigen Algorithmus genommen, da ein Festlegen von ROIs auch manuell später erfolgen kann, falls es nötig sein sollte. Das bedeutet, dass *YOLO* auch manuell als zweistufiger Algorithmus programmiert werden kann. Ein zweistufiger Detektionsalgorithmus, wie R-CNN, arbeitet bei umfangreichen TZ, in denen sich die Objekte auf eine kleine Fläche (Welle) konzentrieren, ineffektiver als ein einstufiger. Beim Vorliegen von vielen Bauteilen in einem kleinen Bildbereich einer TZ, sollte das Festlegen einer ROI, die mehrere Objekte enthält, in dieser Anwendung effektiver sein.

### 4.1 Training

Damit die KI für den Anwendungsfall geeignet detektieren kann, muss diese trainiert werden. Das Training wird supervised learning genannt, weil klassifizierte Trainingsdaten bereitgestellt werden, mit denen gezielt auf einen Aspekt bzw. Ziel hin trainiert wird (siehe Unterkapitel 2.7). In diesem Fall ist dies die Erkennung von Bauteilen in einer TZ. Im Gegenteil dazu wurde *ChatGPT* mit unsupervised learning angeleitet, indem sich der Algorithmus Daten aus dem Internet selbst heraus sucht und diese analysiert. Muster und Zusammenhänge in Daten werden explorativ erforscht.

Die Trainingsdaten setzen sich in dieser Arbeit aus drei verschiedenen Datensätzen zusammen. Diese werden folgendermaßen benannt: synthetische, manuelle und gemischte Trainingsdaten. Hinter den synthetisch generierten Trainingsdaten verbirgt sich ein Algorithmus, der automatisiert Trainingsbilder mit Label generiert. Dieser wird in Unterkapitel 4.3, Optimieren der KI-Detektion, genauer vorgestellt. Der manuelle Trainingsdatensatz beinhaltet Bilder, dessen Inhalte händisch gelabelt sind. Eine Mischung der beiden genannten Datensätze bildet den gemischten Trainingsdatensatz (Mixed Data).

### 4.1.1 Labeln von Trainingsdaten

Beim supervised Learning werden gelabelte Trainingsdaten für das Lernen verwendet, welche die Positions- und Größendaten einer Klasse enthalten. Als Beispiel wird das Labeln anhand eines Kugellagers vorgenommen (siehe **Abbildung 4.1**). Die Klasse des Rillenkugellagers umfasst das komplette Lager als ein Objekt in Form einer rechteckigen Markierung. Es gibt Softwareprogramme, die aus diesem Rechteck die Positions- und Größendaten automatisch erzeugen. Die Ausgabe dieser Zahlenreihe sieht so aus:

```
1 0.4223 0.6021 0.1553 0.0554
```

Die erste Zahl (1) definiert die Klasse. Danach werden die Positionsdaten des Objektmittelpunktes angegeben. Die Werte sind jeweils durch ein Leerzeichen getrennt. Als Werte werden relative Anteile ausgegeben, damit eine Skalierungsunabhängigkeit gegeben ist. In diesem Fall befindet sich der Mittelpunkt des Rechtecks bezogen auf die Abzisse bei 42,23% der dimensionslosen Länge in der Bildbreite. Die letzten beiden Werte werden ebenfalls relativ angegeben und spiegeln die Höhe und Breite des Rechtecks wider.

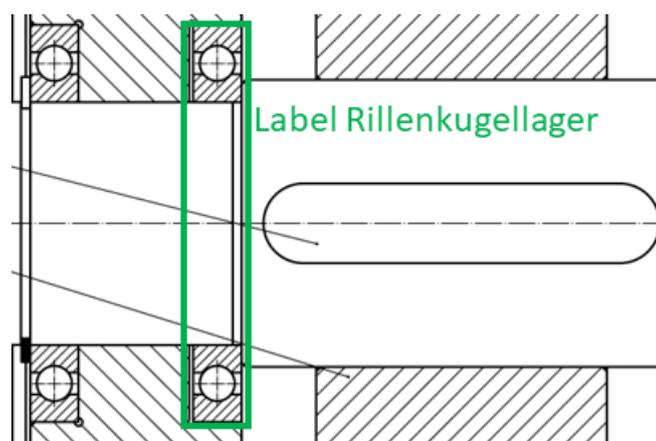


Abbildung 4.1: Label des Rillenkugellagers

### 4.1.2 Definition der zu erkennenden Klassen

Im letzten Absatz wird das Labeln der Trainingsdaten beschrieben. Als nächstes müssen die zu erkennenden Klassen definiert werden. In diesem Fall wird z. B. die Klasse Radialwellendichtring (RWDR) eingeführt. Eine Zusammenstellung der zu erkennenden Bauteile ist in **Tabelle 4.1** gezeigt. Hier werden überwiegend Normteile definiert, weil diese Objekte einzigartige, meist genormte Merkmale aufweisen. Die exakte Definition wird in den nächsten Abschnitten erfolgen. Es werden hier im ersten Versuch ebenfalls geometrische Elemente der Welle mit einbegriffen, damit die Erkennungsqualität von Objekten mit wenig detailreichen Merkmalen analysiert werden kann.

Tabelle 4.1: Definierte Klassen für die Objekterkennung nach [Kra22]

Klassen-Nummer	Bezeichnung der Klasse
0	RWDR_real
1	Wellenmutter
2	Freistich
3	Fase
4	Sicherungsring
5	Zentrierbohrung
6	Ritzelwelle
7	Passfeder
8	Gewinde
9	Sicherungsblechnut
10	Wellenmutter und Sicherungsblech
11	O-Ring
12	Schräggugellager
13	Rillenkugellager
14	Bohrung
15	Distanzbuchse
16	RWDR_einfach

#### Klasse Wellenmutter

Eine Wellenmutter wird zur Festlegung von Bauteilen auf einer Welle eingesetzt. Sie besitzt ein Innengewinde und lässt sich auf eine Welle aufschrauben. Da Wellenmutter auch ohne Sicherungsblech vorkommen (bspw. beim Kontern), wird eine Klasse als reine Wellenmutter festgelegt. Diese ist in **Abbildung 4.2** dargestellt, in der gezeigt wird, wie das Label der Klasse festgelegt ist.

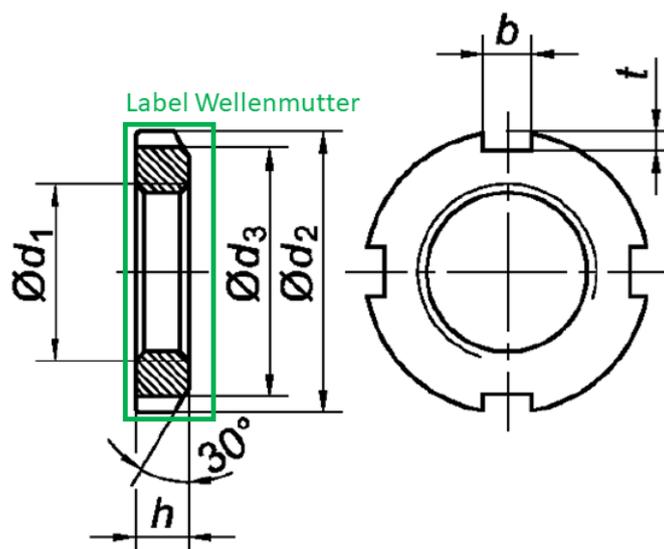


Abbildung 4.2: Wellenmutter und Synthese zur Definition der Klasse nach [Deu09]

### Klasse RWDR

Der Radialwellendichtring ist eine Standarddichtung gegen Ölverlust und wird bei rotierenden Teilen wie z. B. Wellen eingesetzt [Kü16]. Der Radialwellendichtring wird in zwei Klassen aufgeteilt, weil es verschiedene Darstellungsformen des Normteils in TZ gibt. Zum einen existiert die vereinfachte Darstellung (siehe **Abbildung 4.3** links), sowie die „reale“ Darstellung (siehe Abbildung 4.3 rechts). Für die vereinfachte Darstellung gibt es eine weitere Möglichkeit der Pfeildarstellung, welche die diagonale Linie ergänzt. Diese Darstellungsformen werden als Klasse 0 (realer RWDR) und Klasse 16 (RWDR vereinfacht) definiert. Die reale Darstellung beinhaltet den Aufbau mit Zugfeder, Schutzlippe, Dichtlippe und Membran. Es gibt darüber hinaus auch umfangreichere Aufbauten des RWDR, die jedoch nicht in dieser vorliegenden KI-Objekterkennung behandelt werden. Der RWDR wird über den gesamten Durchmesser hinweg gelabelt, weil es sich um das gesamte Bauteil handelt.



Abbildung 4.3: Gegenüberstellung der gängigen Darstellungsformen des RWDR in TZ nach [Kü16]

### Klasse Freistich

Freistiche sind Einkerbungen in einer Welle und erfüllen zwei Aufgaben. Erstens werden Bearbeitungsausläufe für Werkzeuge bei Passflächen gewährleistet und zum anderen wird der Kraftfluss bei Querschnittssprüngen verbessert, wodurch der Kerbeffekt verringert wird. Freistiche werden üblicherweise in vereinfachter Form innerhalb von TZ dargestellt

(siehe **Abbildung 4.4**). Diese lassen sich geometrisch als Rechteck beschreiben, was eine Erkennung besonders schwierig macht, weil dies kein einzigartiges Merkmal ist, das mit einer hohen Sicherheit erkannt wird. Es wird trotzdem versucht, diese Klasse anzulernen.

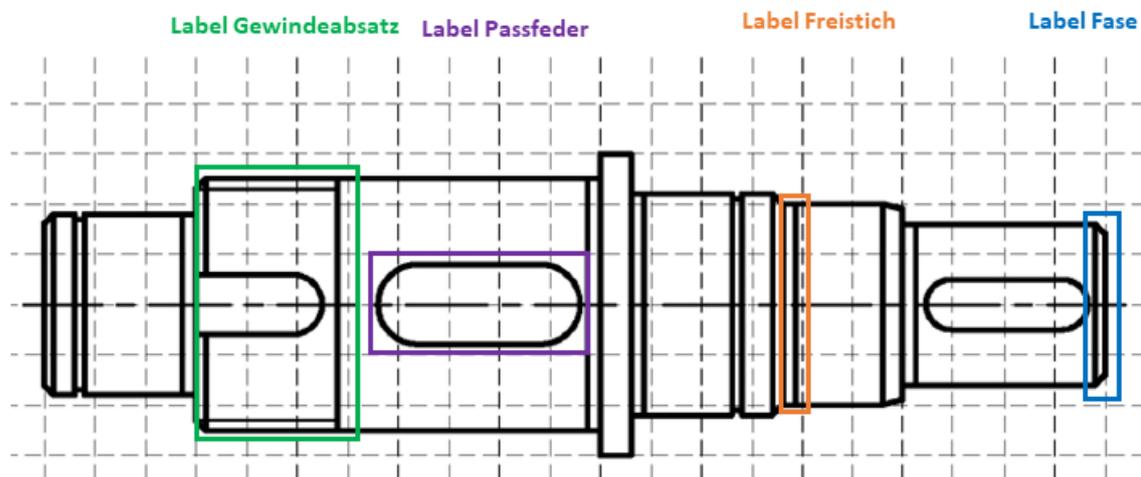


Abbildung 4.4: Einige Label zusammengefasst auf einer Welle nach [Kü16]

#### **Klasse Fase**

Eine Fase ist eine abgeschrägte Fläche, an der sich vorher eine scharfe Kante befand. Sie werden zum Entgraten und als Montagehilfe eingesetzt. Fasen können in verschiedenen Ausführungen vorliegen. Üblich ist eine  $45^\circ$  Fase, während bei der Verwendung von RWDR Fasen von  $15^\circ - 30^\circ$  laut Norm angebracht werden müssen (siehe **Abbildung 4.4**). Die Fase wird, wie der Freistich, über den gesamten Wellendurchmesser definiert, um eine gewisse Identitätstiefe zu erreichen.

#### **Klasse Sicherungsring**

Der Sicherungsring ist ein in eine Nut der Welle aufgestülpter Ring, der zur axialen Lagesicherung dient. Dieser wird ebenfalls als Bildausschnitt über den Wellendurchmesser festgelegt. So werden mehr Merkmale verarbeitet, da der Ring auf einer Seite der Welle geschnitten und auf der anderen Seite nicht geschnitten dargestellt wird.

#### **Klasse Ritzelwelle**

Eine Ritzelwelle ist eine Welle, bei der die Verzahnung bei der Herstellung bereits mit gefertigt wird. Die eingebrachten Zähne sind ein Teil der Welle. Im Gegensatz dazu gibt es die Möglichkeit, ein Zahnrad als separates Bauteil zu fertigen und erst bei der Montage mit der Welle zu verbinden. Eine Ritzelwelle ist in **Abbildung 4.5** dargestellt. Diese wird als Bauteil über den gesamten Wellendurchmesser gelabelt.

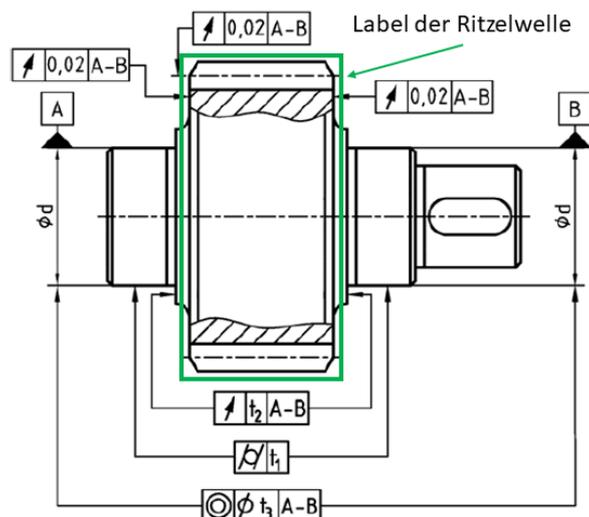


Abbildung 4.5: Label auf einer Ritzelwelle nach [KW19]

### Klasse Passfeder

Eine Passfeder hat die Aufgabe Drehmomente zwischen einer Welle und einer Nabe (z.B. ein Zahnrad) zu übertragen. In der Abbildung 4.4 und der Abbildung 4.5 sind am jeweiligen Wellenende eine Passfeder bzw. Passfedernut zu sehen. Dabei wird die gesamte Passfeder gelabelt. Es existieren Wellenzeichnungen, in denen die Passfeder an der Mittellinie gebrochen wird. Da diese Darstellung seltener vorkommt, wird diese hier nicht berücksichtigt. Es wird vorausgesetzt, dass eine Passfeder gänzlich zu sehen ist. Allerdings wird eine weitere Darstellung des Öfftens verwendet, bei der die Passfeder an der oberen Kante des Wellendurchmessers geschnitten dargestellt wird. Diese Darstellung wird vernachlässigt, da das Vorgehen in der Arbeit zunächst die Machbarkeit prüfen soll und kein Recht auf die Vollständigkeit bezüglich in TZ vorkommenden Bauteilen erhebt.

### Klasse Gewinde

In Abbildung 4.4 ist ein gelabelter Gewindeabschnitt auf der Welle zu sehen. Bei dieser Klasse wird der gesamte Absatz gelabelt, auch auf die Gefahr hin, dass andere Bauteile innerhalb der BB liegen. Alternativ können die parallelen Linien der Gewindedarstellung gelabelt werden.

### Klasse Sicherungsblechnut

Das Sicherungsblech mit dazugehöriger Sicherungsblechnut wird gemeinsam mit einer Wellenmutter verwendet und dient als Verdrehsicherung, damit sich die Wellenmutter durch die Drehmomentbelastung nicht von der Welle löst. Dafür wird das Sicherungsblech in die Nut der Welle geführt und zum anderen wird das Blech an einer Stelle in eine freie Nut der Wellenmutter eingestülpt bzw. „reingebogen“. Die Sicherungsblechnut befindet sich in Abbildung 4.4 innerhalb des Labels für den Gewindeabsatz. Das Label schließt die gesamte Geometrie ein.

### Klasse Wellenmutter mit Sicherungsblech

Zur Klasse Wellenmutter wird eine Klasse aus der Kombination aus Wellenmutter und Sicherungsblech ergänzt. Die Darstellung des Bauteilpaares unterscheidet sich von der einer alleinigen Wellenmutter. In **Abbildung 4.6** rechts neben Zahnrad und Distanzbuchse ist das Sicherungsblech auf der einen Seite in eine Nut der Wellenmutter eingelassen. Eine alternative Festlegung der Klassen Wellenmutter und Wellenmutter mit Sicherungsblech ist das „Wellenmutterpaket“, in der bei zwei konternden Wellenmuttern direkt beide zusammengefasst werden.

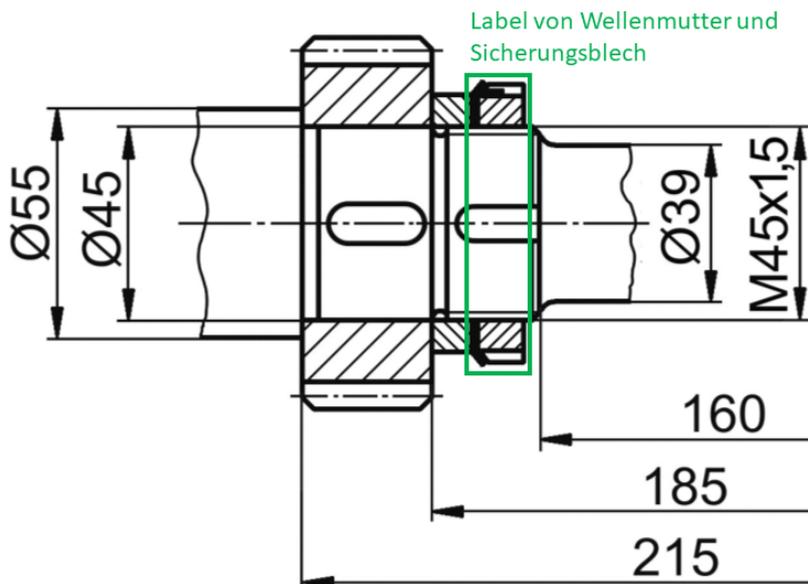


Abbildung 4.6: Label von Wellenmutter und Sicherungsblech nach [KW19]

### Klasse O-Ring

Der O-Ring ist ein Dichtring, der Fluide daran hindert aus- bzw. einzudringen. Er wird in einem der angrenzenden Bauteile in eine Nut eingeführt, sodass die Lage eindeutig bestimmt ist. Es wird unterschieden nach radial außendichtend und radial innendichtend. Das Label des in **Abbildung 4.7** dargestellten O-Rings wird über den gesamten Durchmesser festgelegt. Das Labeln runder schraffierter Querschnitte ist mehrdeutig und wird deshalb vermieden. [Kü16]



Abbildung 4.7: Radial außendichtender O-Ring

### Klasse Schrägkugellager

Wälzlager bestehen in ihrer Grundform aus einem Rollkörper (hier Kugel), einem Innen- und Außenring, sowie einem Käfig. Es können auch noch andere Bauteile

bei bestimmten Bauformen dazukommen, wie eine Dichtung, die direkt in einem Lager integriert ist. Innerhalb dieser Klassendefinition wird bei Wälzlagern jedoch von der einfachsten Grundbauform ausgegangen. Eine Kugellagerbauform, die auch für höhere axiale Kräfte geeignet ist, ist das Schrägkugellager. Das in **Abbildung 4.8** abgebildete, gelabelte Lager erhält eine eigene Klasse. Über Kugellager hinaus werden in dieser Machbarkeitsstudie keine weiteren Lager in das KI-Modell eingepflegt, weil eine Erweiterung des Erkennungsbaukastens nur eine Frage der Quantität sein sollte.

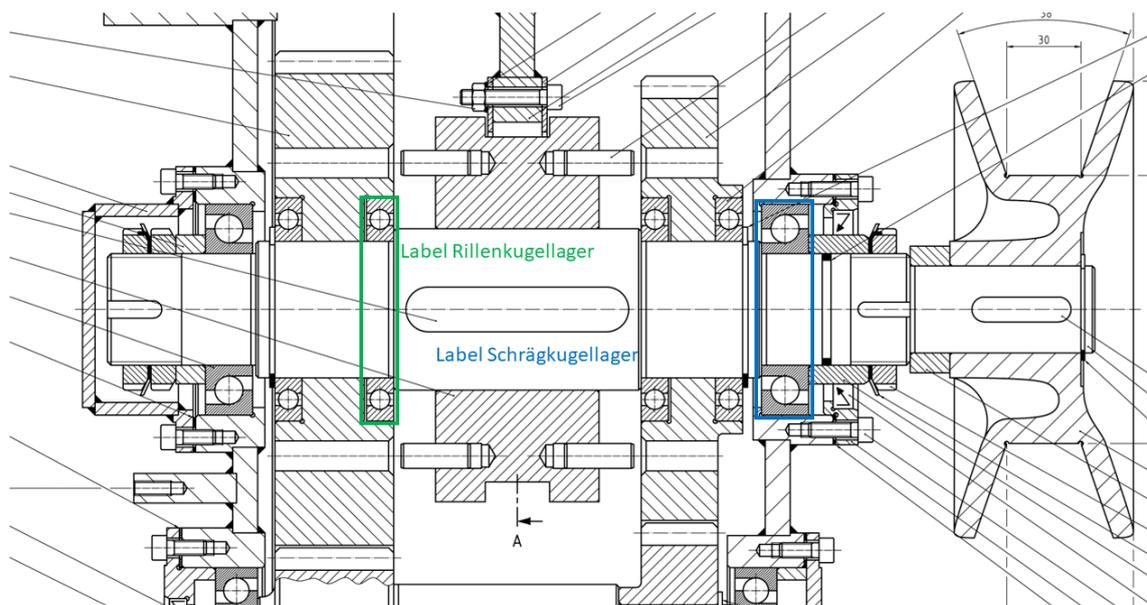


Abbildung 4.8: Label des Schrägkugellagers und des Rillenkugellagers nach [Sch21]

#### **Klasse Rillenkugellager**

Ein Rillenkugellager gehört zur Gruppe der Wälzlager und unterscheidet sich zum Schrägkugellager insofern, als dass Innen- und Außenring symmetrisch zur Mittellinie des Lagers, welche parallel zur Wellenachse verläuft, sind, also keine Flanken an den Seiten aufweisen. Dadurch können Sie nicht so hohe Axialkräfte übertragen. In diesem Zusammenhang ist ebenfalls auf die Ausgewogenheit der Trainingsdaten zu achten, weil alle Darstellungsformen der Lager mitberücksichtigt werden sollten (z. B. unterschiedliche Darstellung der Mittellinien), da die aus Unterkapitel 2.8 erwähnten Probleme wie overfitting auftreten können.

#### **Klasse Bohrung**

Eine Bohrung ist eine zylindrische Volumensubtraktion, die mittels eines Bohrers hergestellt werden kann. Das Label der Klasse Bohrung ist in **Abbildung 4.9** dargestellt. Es werden Durchgangsbohrungen und Sacklochbohrungen mit inbegriffen.

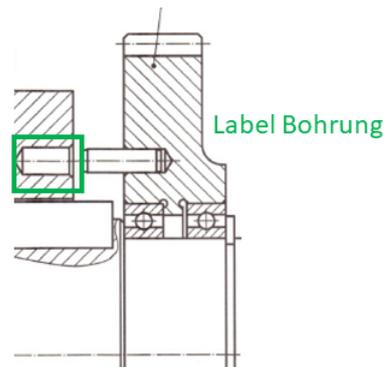


Abbildung 4.9: Label einer Bohrung

### Klasse Distanzbuchse

Eine Distanzbuchse ist ein zylindrischer Ring, der Abstände überbrücken und Kräfte übertragen kann. Die Distanzbuchse wird jeweils an den Wellenabsätzen einzeln gelabelt, weshalb für eine Distanzbuchse zwei Markierungen vorliegen. Mit Hilfe dieser Klasse soll überprüft werden, welche Detektionsqualität mit merkmalarmeren Objekten erreicht werden kann.

### 4.1.3 Konfigurationsparameter Training

Für das Lernen der KI können mehrere Konfigurationsparameter angepasst werden, um das Training zu optimieren. Die Einflussgrößen, die sich auf die Detektionsqualität auswirken, sind in **Abbildung 4.10** dargestellt. Die Vorversuche zeigen, welche Einflussgrößen für die Anwendung priorisiert betrachtet werden sollen.

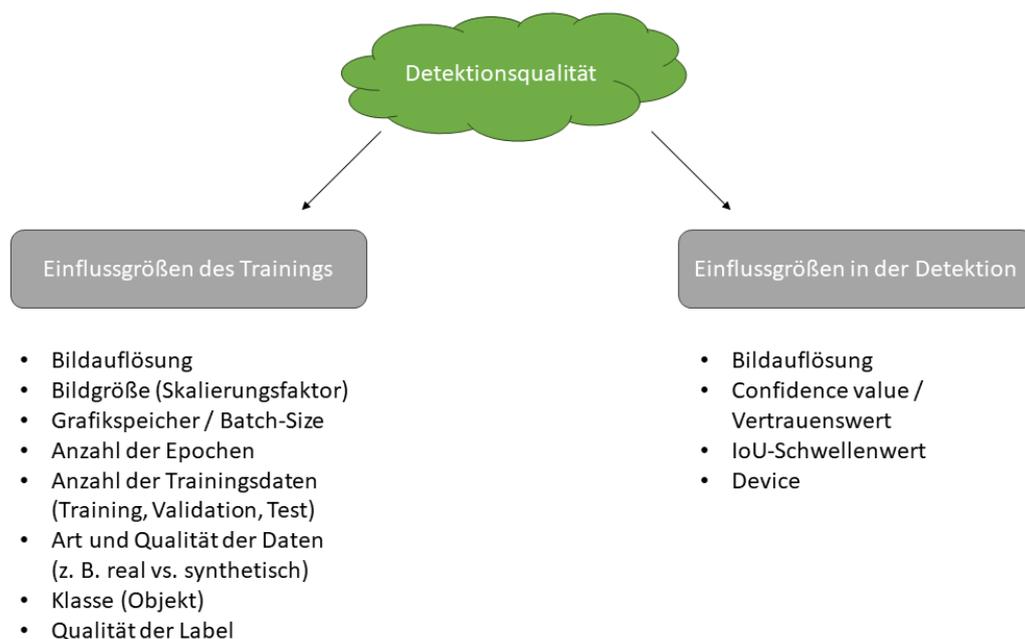


Abbildung 4.10: Einflussgrößen der Detektionsqualität

Die Batch Size gibt an, wie viele Bilder in einer Iteration verwendet werden. Nach einer Iteration wird das NN mit den Gewichtungen angepasst. Wenn die Batch Size gering ist, sodass nur wenige Bilder pro Aktualisierung des Netzes verwendet werden, ist die Gefahr größer, dass das Training nicht in die gewünschte Zielrichtung läuft (underfitting). Bei der Batch Size ist es wichtig, dass alle auf einmal verarbeiteten Bilder in den Grafikspeicher passen. In einer Epoche werden mehrere Iterationen durchgeführt, sodass alle verfügbaren Trainingsbilder pro Epoche verarbeitet werden.

Für den Trainingsprozess können die Höhe und Breite eines Bildes in Pixel als Eingabeparameter angepasst werden. Bei starken Veränderungen des NN ist die Wahrscheinlichkeit für Überspringen größer, woraus over- und underfitting resultieren können. Laut verschiedenen Quellen ist die Anzahl der Trainingsdaten in Abhängigkeit zu der Anzahl der Klassen  $n_k$  zu wählen. Würz [Wü21] empfiehlt pro Klasse 2000 Trainingsbilder zu verwenden. Im vorliegenden Fall sollen bei der Definition von 17 verschiedenen Klassen demnach 34.000 Trainingsdaten für das Anlernen der KI verwendet werden. *Nowruzi et al.* untersuchten den Einfluss mit Datensätzen und nutzen für zwei Klassen bis zu 15 000 Trainingsdaten [Now19]. Andere Quelle geben ein Minimum von 100-500 Trainingsdaten pro Klasse an [Cho15; Sha20].

## 4.2 Vorversuche zum Herausstellen der Einflussgrößen

Für die Vorversuche werden sowohl die Daten des Trainings als auch die Detektionen in TZ analysiert. In diesem Unterkapitel werden die oben angeführten Einflüsse ausgewertet, um Ansätze zur Verbesserung der Detektionsqualität zu eruieren. Die verwendeten Trainingsparameter für die Vorversuche sind in der **Tabelle 4.2** aufgeführt. Durch die begrenzte Verfügbarkeit an geeigneten TZ für das Training werden alle vorliegenden realen Getriebezeichnungen (300) verwendet, um die Vorversuche durchzuführen. Zunächst werden Bildgrößen von 512 Pixel für das Training verwendet. Damit können pro Batch 8 Bilder verarbeitet werden.

Tabelle 4.2: Trainingsparameter der Vorversuche

Trainingsparameter	Werteintervall
Batch Size	2 bis 8 Bilder
Bildgröße	512 bis 1600 px
Epochen	Bis zu 2000
Anzahl der Trainingsbilder	300
GPU	<i>NVIDIA RTX 3070</i> (8 GB VRAM)
Anteil Validierungsdaten	10% der Trainingsbilder

### 4.2.1 Auswertung der Vorversuche

Für die Vorversuche werden 300 gelabelte Zeichnungen für das Training verwendet (siehe Tabelle 4.2). Die TZ werden innerhalb einer Semesteraufgabe von Studierenden erstellt und gelten als Klausurleistung. Die Bildgröße der Trainingsbilder wird auf eine Bildbreite von 512 Pixel festgesetzt. Dies führt bei einem konstanten Skalierungsfaktor zu einer Bildhöhe von 362 Pixel. Mit dieser Bildgröße können acht Bilder pro Batch gleichzeitig verarbeitet werden, wenn mit einer *NVIDIA RTX 3070* mit 8 GB VRAM trainiert wird. Es wird über 2000 Epochen trainiert. Der Anteil der Validierungsdaten beträgt 10% der Anzahl des insgesamt vorliegenden Bilddatensatzes. Ein Beschaffen geeigneter TZ mit allen enthaltenen definierten Klassen erweist sich als schwierig. Aufgrund des geringen Umfangs des Trainingsdatensatzes wird die untere Grenze der empfohlenen Anzahl der Validierungsdaten genutzt.

Die in **Abbildung 4.11** dargestellten Diagramme entsprechen der Ausgabe von *YOLO* nach dem Training. Das linke Diagramm zeigt die Häufigkeit der in den Trainingsdaten vorkommenden Klassen. Freistriche und Fasen stechen hier heraus, weil diese an einer Welle häufig mehrfach anzutreffen sind. Auf der rechten Seite wird die Häufigkeitsverteilung der Objekte im Bildraum betrachtet. Hier stellt sich heraus, dass die zu erkennenden Objekte häufig in der Bildmitte zu finden sind und die Breite einer Welle größer ist als der Durchmesser (rot bedeutet am häufigsten). Die Mittellinie der Welle ist stets horizontal ausgerichtet.

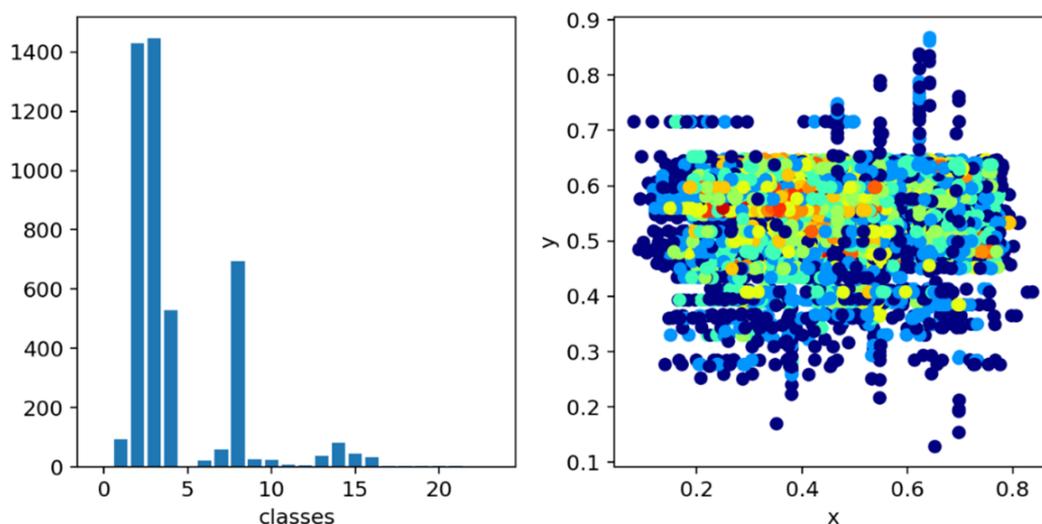


Abbildung 4.11: Verwendete Klassen und Vorkommen der Objekte im Bildraum [Kra22]

In der nächsten **Abbildung 4.12** ist die Verteilung der relativen Objektgröße dargestellt. Dies stellt den Zusammenhang zwischen der Bildgröße ( $h=1$ ;  $w=1$ ) und der Objektgröße her. Wenige Objekte nehmen in etwa die Hälfte der Höhe und Breite des Bildes an. Dies sind in der Höhe die Zahnräder und in der Breite die Passfedern. Die meisten Objekte sind kleiner als 10% der Bildhöhe und 20% der Bildbreite

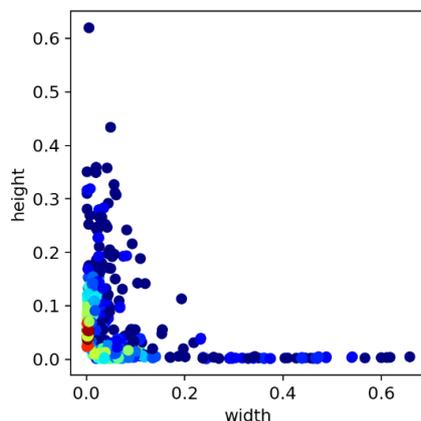


Abbildung 4.12: Verteilung der relativen Objektgröße [Kra22]

In der **Abbildung 4.13** sind die Trainingsergebnisse des Vorversuchs zu sehen. Im ersten Graph oben links ist der GIoU-Verlustwert zu sehen. Auf der Abzisse ist die Anzahl der Epochen aufgetragen. Bei der Betrachtung der in **Abbildung 4.13** gezeigten Diagramme wird ersichtlich, dass sich der GIoU-Verlustwert und die Klassifikation ähnlich verhalten. Der Verlustwert beschreibt die Subtraktion des GIoU-Wertes von der Zahl eins. Ist der Verlustwert gleich 0, dann beträgt der GIoU-Wert eins. Mit sinkendem Graphen verbessert sich der GIoU-Wert. Gleiches gilt für die Objectness (Objektivität) und die Klassifikation. Der Klassifikations-Verlustwert beschreibt die Genauigkeit der Klassifikation sowie der Lokalisation. Er setzt sich zusammen aus der Multiplikation der Wahrscheinlichkeit, also dass sich in der BB das detektierte Objekt tatsächlich befindet, und der Genauigkeit der Lokalisation (IoU).

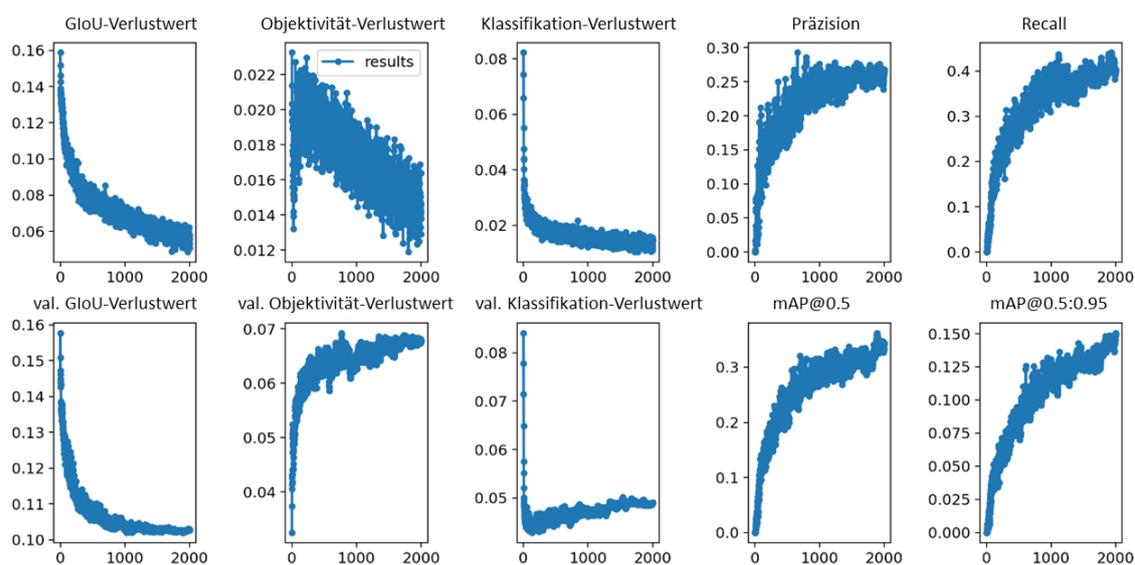


Abbildung 4.13: Werte des Trainings des Vorversuchs nach [Kra22]

Es zeigt sich, dass der GIoU-Verlustwert mit zunehmender Trainingsdauer abnimmt, bis dieser eine Sättigung bei einem Wert von 0,06 erreicht. Das bedeutet, dass die

Überlappung von BB und tatsächlicher Objektraum mit zunehmendem Training weiter zunimmt. Genauso steigt die Präzision an und erreicht knapp mehr als 0,25. Bereits bei 1000 Epochen erreicht die Präzision ihre obere Schranke. Daraus kann geschlussfolgert werden, dass falsch positive Ergebnisse zu erwarten sind. Der Verlauf des Recalls ist analog und erreicht die Marke von 0,4. Dies bedeutet, dass die falsch-negativ-Rate erhöht sein wird. Auch der mAP-Wert nimmt mit zunehmender Epochenanzahl zu. Dieser erreicht einen Maximalwert von 0,33. Insgesamt liegen die Präzision, der Recall und die mAP-Werte auf einem niedrigen Niveau. Es lässt sich dadurch erklären, dass nur wenige Trainingsdaten vorliegen. Gute Werte liegen in der Regel bei 0,8 bis 0,9 und sehr gute Werte zwischen 0,9 und 1.

Die Verfügbarkeit an qualitativ hochwertigen Zeichnungen bzw. Trainingsdaten ist gering und sollte im weiteren Verlauf erhöht werden. Außerdem ist das erhöhte Vorkommen an falsch negativen und falsch positiven Detektionen ein Zeichen dafür, dass die Merkmale der Klassen nicht gut erkannt werden bzw. die Merkmalgüte zu gering ist. Dies wird in den nächsten Schritten näher untersucht. Die Objektivität ist ein Maß für die Wahrscheinlichkeit, dass sich ein Objekt in der BB befindet. Die Verlustwerte sind hingegen als gut zu bewerten. Die Objektivität nimmt von Anfang an zu. Dieser oben abgebildete Verlauf deutet also darauf hin, dass das Anlernen der KI nicht in die gewünschte Richtung verläuft, sodass die Detektionsqualität gemildert wird.

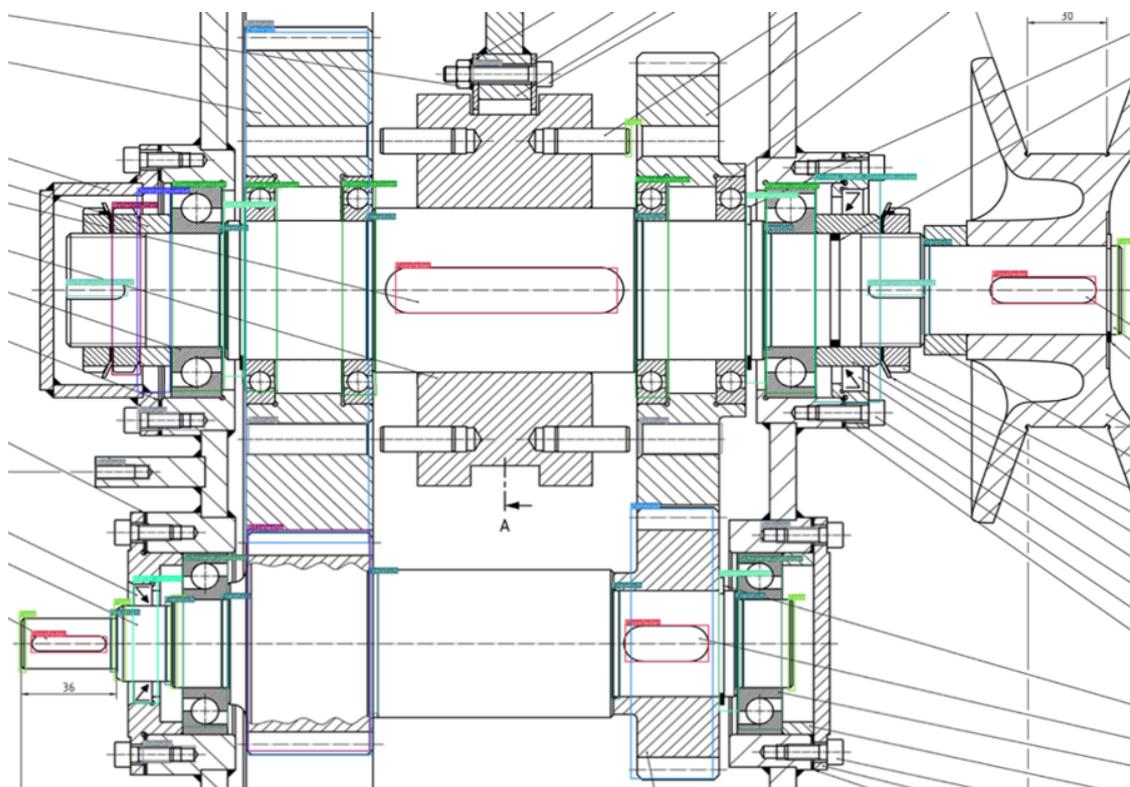


Abbildung 4.14: Detektionen in einer Getriebezeichnung nach [Sch21]

In der **Abbildung 4.14** sind die Detektionen des KI-Algorithmus *YOLOv4* an einer TZ zu sehen. Es ist zu erkennen, dass einige Klassen besser zu detektieren sind als andere. Bspw. werden Lager grundsätzlich gut erkannt, wohingegen Bohrungen schlechter erkannt werden. Ein Rillenkugellager wird unter den Zahnrädern nicht erkannt und die BB stimmt teilweise nicht mit dem Objekt überein, weil die Detektion eine zu kleine BB aufweist. Zudem werden Distanzbuchsen nicht gut erkannt. Bei der Passfeder ist auffällig, dass die BB nicht das gesamte Objekt einschließt.

Wellenmuttern mit Sicherungsblechen werden ebenfalls nicht zuverlässig erkannt. Gleiches gilt für O-Ringe und Fasen. Der oben links befindliche Zahn des Zahnrades wird als Bohrung erkannt. Hier liegt eine Klasse vor, die nicht für diese Art der Objektdetektion geeignet ist, da keine eindeutigen Merkmale vorliegen. Zahnräder werden teilweise erkannt. Mehrere Erkennungen im gleichen Raum erschweren die Detektion. Es ist möglich, dass sich bei Zahnrädern neben Passfedern auch Lager, Bohrungen und axiale Sicherungselemente innerhalb der BB befinden. Daher wird die Klasse auf die Erkennung der Zähne reduziert werden. Zudem ist auffällig, dass Sicherungsringe nicht erkannt werden. Dies kann an den verschiedenen Darstellungsvariationen liegen (geschwärzt und nicht geschwärzt).

Wie bereits bei der Definition der Klasse beschrieben, reichen die wenigen Merkmale einiger Klassen anscheinend nicht aus, um eine zuverlässige Detektion zu gewährleisten. Darüber hinaus lässt sich feststellen, dass die BB der Detektion oftmals nicht sehr präzise mit dem tatsächlichen Objektraum übereinstimmt. Insgesamt ist die Detektion von Klassen, die wenig markante Merkmale aufweisen und eine geringe relative Größe besitzen, unzuverlässig. Hierzu zählen besonders Bohrungen, Freistiche und Fasen. Diese Klassen sind dafür verantwortlich, dass sich die obigen Trainingswerte auf einem verhältnismäßig niedrigen Niveau im Vergleich zum Stand der Technik befinden und falsch positive sowie falsch negative Erkennungen vermehrt auftreten. Insgesamt sorgen die niedrigen Trainingswerte dafür, dass der Vertrauenswert sehr niedrig eingestellt werden muss, damit Markierungen durch den Detektor getätigt werden. Das sorgt im Gegenzug dafür, dass die Wahrscheinlichkeit für falsch negative Ergebnisse zunimmt. Der Ausschnitt der Getriebezeichnung ist relativ klein ( $\frac{1}{5}$  des Gesamtbildes), sodass Merkmale mit dem menschlichen Auge nur schwer wahrzunehmen sind. Es bietet sich an, die Objekterkennung auf lokaler Ebene durchzuführen, indem spezielle Bereiche fokussiert werden (Festlegen von ROI).

### 4.2.2 Optimierungsansätze der Detektionsqualität

Die Vorversuche wurden mit einer geringen Trainingsdatengröße von etwa 300 gelabelten Zeichnungen trainiert. Dies ist weniger als empfohlen wird. Daher ist ein

Optimierungsansatz die **Erhöhung des Trainingsdatensatzes**. Es ist jedoch schwierig an viele geeignete Trainingsbilder zu gelangen. Für Anwender\*innen bedeutet dies einen sehr großen Aufwand, weil viele Bilder gelabelt werden müssen. Daher wird nach einer Möglichkeit gesucht, um diesen Aufwand zu verringern und gleichzeitig geeignete Trainingsdaten zu erhalten. Wie im nächsten Unterkapitel beschrieben, wird auf die automatische Erstellung von Trainingsdaten zurückgegriffen. Dadurch kann der Trainingsdatensatz synthetisch vergrößert werden. Neben der Vergrößerung des Trainingsdatensatzes wird auch Wert auf die Vielfalt der Trainingsdaten gelegt, damit die KI-Detektion nicht nur eingeschränkt, sondern auch in anderen Anwendungen genutzt werden kann. Eine Übertragbarkeit auf andere Problemstellungen und Themengebiete ist einfach möglich.

Auf der anderen Seite befinden sich die Trainingswerte Präzision, Recall und mAP auf einem niedrigen Niveau. Deshalb wird im nächsten Unterkapitel ein **Neu-Definition der Klassen** vorgenommen. Damit kann der Einfluss von Merkmaleigenschaften analysiert werden. Außerdem ist es ratsam, den Einfluss einiger Parameter genauer zu untersuchen. Dies betrifft bspw. die Bildgröße. Mit steigender **Bildgröße** nimmt die Menge an zu verarbeitenden Daten zu. Dies macht ein **Hardwareupgrade** unumgänglich. In weiteren Versuchen wird daher eine *NVIDIA RTX 3090 Ti* verwendet, damit größere **Bildgröße und Auflösungen** bei gleichzeitig größerer Batch Size im Training verarbeitet werden können. Des Weiteren wird der Einfluss der Trainingsdaten im Hinblick auf die Art der Erstellung (synthetisch, manuell und gemischt) analysiert.

### 4.3 Optimieren der KI-Detektion

Die Optimierung der KI-Detektion gliedert sich in drei Abschnitte. Zunächst werden Maßnahmen ergriffen, die den Trainingsdatensatz betreffen, indem dieser vergrößert wird. Danach werden Maßnahmen durchgeführt, welche die Neu-Definition von Klassen und die Konfigurationsparameter betreffen.

#### 4.3.1 Automatische Erstellung von Trainingsdaten

Eine automatische Erstellung von Trainingsdaten wird mittels eines Algorithmus erreicht. Dieser konstruiert eigens Wellen mit aufgesetzten Bauteilen nach Normen und Berechnungsgrundlagen des Ingenieurwesens. Es ist angelehnt an automatisierte Wellengeneratoren, den CAD-Systeme teilweise mitbringen. Das Besondere an diesem Algorithmus ist jedoch, dass dieser direkt das Labeln mit übernimmt. Falls ein Bauteil an einer Stelle auf der Welle platziert wird, wird mit einer Toleranz ein Rechteck mit Hilfe der Zahlenreihe aus Abschnitt 4.1.1 definiert, die in eine Text-Datei geschrieben

wird. Das Bild und die Text-Datei werden in dem Format abgelegt, welches für das Trainieren der KI benötigt wird, sodass diese nicht mehr nachbearbeitet werden müssen. Sie können sofort für das Anlernen der KI verwendet werden.

In **Abbildung 4.15** ist eine automatisch erstellte Welle zu sehen. In diesem Bild sind viele der zu erkennenden Klassen enthalten. Für die Machbarkeitsstudie werden zweigängige Getriebe ausgewählt, weil diese eine Vielzahl von typischen Bauteilen, die im Maschinenbau verwendet werden, enthalten. Außerdem kann der Algorithmus dann später für die Lehre eingesetzt werden, da die Studierenden solch ein Getriebe im Studium als Prüfungsleistung konstruieren. Die Variationsparameter zur Erstellung der synthetischen Zeichnungen sind u. a. die Absatzdurchmesser unter den Hauptlagern, die Größe der Zahnräder und die Verwendung von verschiedenen Bauteilen, sodass die Daten an die realen Zeichnungen eines Konstruktionsprojektes angepasst werden.

Einige Störgrößen, die bei der Detektion der Objekte auftreten können, sind Linien, die das zu erkennende Bauteil schneiden. Dies können Hilfslinien, Bemaßungen oder Schnitte sein. Um dies in den synthetisch erzeugten Daten nachzuahmen, werden durch den Algorithmus zufällig Linien im Bild platziert, welche die zu erkennenden Objekte schneiden. Der Algorithmus ist in der Lage, 100.000 Trainingsdaten innerhalb weniger Stunden zu generieren. Von hier an wird von synthetischen Trainingsdaten gesprochen, die durch den automatisierten Wellengenerator mit Labelfunktion generiert werden. Es ist zu testen, inwiefern sich die Qualität der Detektion durch die synthetisch trainierten Daten im Vergleich zu dem manuell gelabelten Trainingsmodell unterscheidet. Grundsätzlich besitzt der automatische Wellengenerator eine bessere Wiederholgenauigkeit, was den Offset bzgl. der Label betrifft. Es bietet sich an, *YOLO* mit Hilfe dieser Trainingsdaten vorzutrainieren.

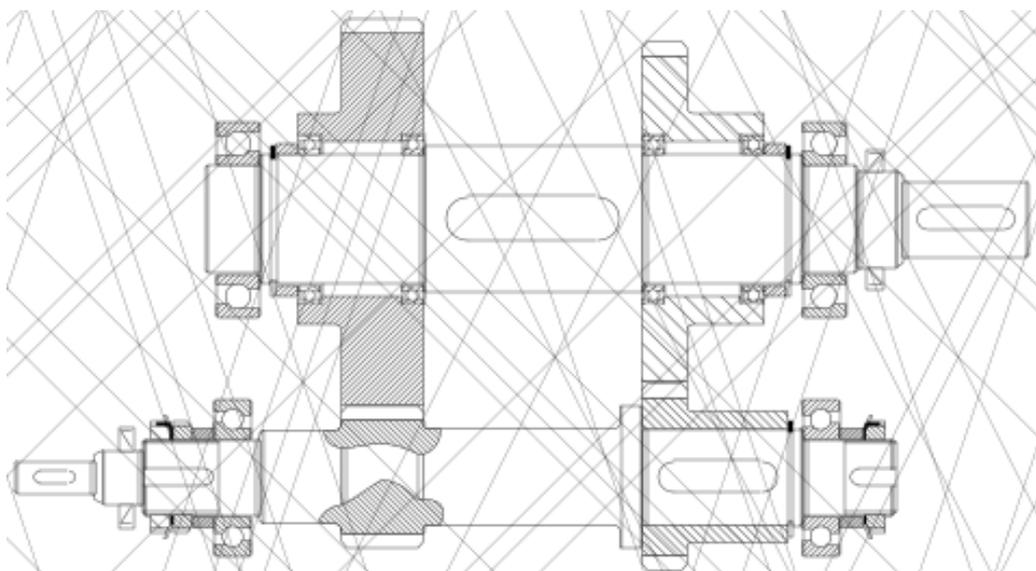


Abbildung 4.15: Generierte Zeichnung des Algorithmus ohne Label mit Störlinien [Kra22]

Eine Auffälligkeit der Abbildung 4.15 ist die unscharfe Darstellung aufgrund der geringen Auflösung des Bildes. Dies liegt daran, dass die DIN A0 großen Zeichnungen innerhalb eines Bildgrößenintervalls von 800 bis 1600 Pixel generiert werden, da dies dem Input in den *YOLO*-Detektionsalgorithmus entspricht. Dadurch verschlechtert sich die Bildauflösung. Außerdem werden diese Abmessungen gewählt, um möglichst nah an der Größe einer Getriebezeichnung zu sein und die Realität so gut wie möglich abzubilden.

### 4.3.2 Optimieren der Konfigurationsparameter und Neu-Definition von Klassen und Labeln

Im Allgemeinen werden die Bildausschnitte der Klassen im Optimierungsmodell so klein wie möglich definiert. Die Vorversuche haben gezeigt, dass sich das Labeln der Klassen über den ganzen Durchmesser als nicht zweckmäßig herausgestellt hat, weil die BB dann übereinander liegen. Dies sorgt dafür, dass der GIoU Wert gehemmt wird, weil sich die Merkmale im Zwischenbereich des Durchmessers nahe dem Mittelpunkt zufällig unterscheiden können. Deshalb werden merkmalarmer Klassen wie zum Beispiel Freistriche und O-Ringe aus der Liste der Klassen entfernt (siehe **Tabelle 4.3**). Die Klassen Bohrung und Zahnrad werden entfernt, weil sich die weitere Analyse auf die Erkennung von Bauteilen bzw. Normteilen fokussieren wird.

Tabelle 4.3: Liste der neu definierten Klassen

Klassen-Nummer	Bezeichnung der Klasse
0	RWDR_real
1	Wellenmutter
2	Sicherungsring
3	Ritzelwelle
4	Zähne
5	Passfeder
6	Gewinde
7	Sicherungsblechnut
8	Wellenmutter und Sicherungsblech
9	Schräggugellager
10	Rillenkugellager
11	RWDR_einfach

Durch die Anpassung der Klassen im Vergleich zu Tabelle 4.1 und der bereits vorhandenen Label, werden Skripte in *Python* erstellt, welche die Klassenneudefinition in den Text-Dateien automatisiert abändert. Dafür mussten die Label-Klassen angepasst

werden und einige Zeilen bzgl. der nicht mehr vorhandenen Klassen gelöscht werden. Damit können die Bilder und Textdateien unter demselben Namen für das Training der KI genutzt werden, sodass an den *YOLO*-Einstellungen nichts verändert werden muss. Damit *YOLO* die Trainingsbilder verarbeitet, müssen die Dateinamen in einer Text-Datei angegeben werden.

##### **Klasse Schrägkugellager**

Innerhalb der Klasse der Schrägkugellager wird das Label insofern verändert, als dass die Markierung nicht mehr über den ganzen Durchmesser gesetzt wird. Stattdessen wird lediglich der Schnitt des Lagers gekennzeichnet, weshalb zwei Markierungen pro Lager gemacht werden (siehe **Abbildung 4.16**). Dies hat den Vorteil, dass durch zwei Detektionen Optimierungen bzgl. Position und Größe durchgeführt werden können. Es kann einmal verglichen werden, ob sich die Mitte der Verbindungsstrecke mit der Mittellinie deckt, und ob die axiale Lage identisch ist. Falls es zu Abweichungen kommt, können Durchschnitte errechnet werden, weshalb die Abweichungen durch die gemittelten Werte abnehmen. Auf der anderen Seite stellt sich die Frage, ob durch die Reduktion der Merkmale, weiterhin eine zuverlässige Detektion stattfinden kann. Dies ist jedoch gegeben, weil Kugel sowie Innen- und Außenring eindeutige Merkmale aufweisen und diese Darstellungsweise einheitlich ist.

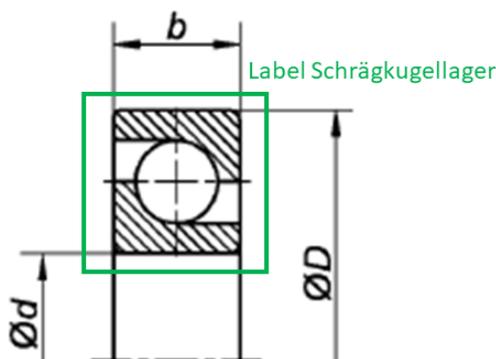


Abbildung 4.16: Neues Label des Schrägkugellagers

##### **Klasse Rillenkugellager**

Bei dieser Klasse wird ebenfalls aus denselben Gründen wie oben beschrieben nur der in der Schnittansicht zu sehende Ausschnitt, analog zum Schrägkugellager, gelabelt. Auch hier sollten die Merkmale ausreichen, dass diese Klasse zuverlässig erkannt wird. Es wird analysiert, ob der Detektionsalgorithmus die verschiedenen Lagertypen eindeutig voneinander unterscheiden kann.

##### **Klasse Wellenmutter**

Die Klasse der Wellenmutter wird auf den in **Abbildung 4.17** gezeigten Ausschnitt begrenzt. Dies gilt ebenfalls für die Wellenmutter mit Sicherungsblech (siehe Tabelle 4.3 Klasse 8). Es werden lediglich die im Schnitt zu sehenden Elemente der beiden

Klassen gelabelt. Dadurch sollen Überschneidungen der Klassen Wellenmutter, Sicherungsblechnut und Gewindeabsatz vermieden werden. Bei dieser Klasse wird überprüft, ob sie qualitativ von der Klasse Wellenmutter mit Sicherungsblech zu unterscheiden ist. Ansonsten bietet es sich an, die Klasse als ganzes Paket zu definieren, also zwei Wellenmuttern mit einem Sicherungsblech zu labeln, falls gekonterte Wellenmuttern zwecks Spieleinstellung auf der Welle vorkommen.

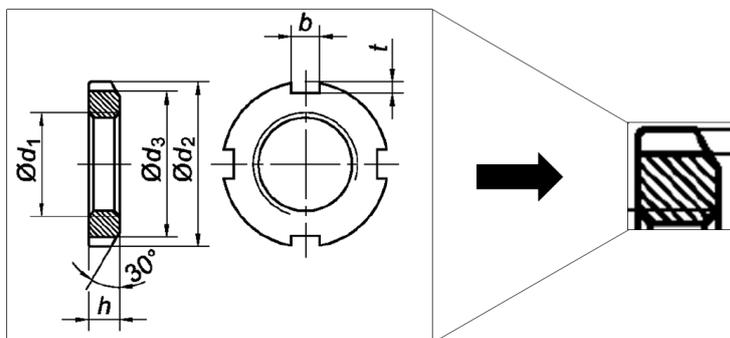


Abbildung 4.17: Neues Label der Wellenmutter nach [Deu09]

### Klassen Ritzelwelle und Zähne

In der neuen Klassenübersicht wird die Klasse 4 „Zähne“ aufgenommen, um es mit der Klasse der Zahnräder und Ritzelwellen vergleichen zu können. Diese Klasse soll jegliche Verzahnungen innerhalb einer TZ erkennen. Dabei wird nur ein Zahn gelabelt. Wenn sich ein Zahnrad auf einer Welle befindet, werden also zwei Zähne markiert.

Auf die Klasse Zahnrad wird aus den bereits genannten Gründen verzichtet. Es können beispielsweise Zahnräder mit Passfedern oder anderen Verspannungsmechanismen sowie kugelgelagerte Zahnrädern vorkommen. Dadurch wird die Wahrscheinlichkeit einer korrekten Erkennung erschwert. Durch die Erkennung der Zähne als Paar, kann nicht nur auf die Zahngröße, sondern ebenfalls auf die Größe und den Mittelpunkt des Zahnrades bzw. der Ritzelwelle geschlossen werden.

### Klasse Sicherungsring

Die Klasse Sicherungsring wird trotz der wenigen aufweisenden Merkmale in die neue Liste mit übernommen, da es sich um ein wichtiges axiales Wellensicherungselement handelt.

### 4.3.3 Verbesserung der Hardwareleistung

Für das anwendungsgerechte Training muss die Hardwareleistung verbessert werden. Dabei wird darauf geachtet, dass eine Aufrüstung auf eine Grafikkarte mit möglichst viel VRAM vollzogen wird. Mit vergrößertem Videospeicher vergrößert sich die zu verarbeitende Batch Size, weil mehr Bilder gleichzeitig bei der Anpassung des NN verarbeitet werden können. Die im Folgenden durchgeführten Trainings werden mit

einer *NVIDIA RTX 3090 Ti* durchgeführt. Damit steigt die Batch Size auf eine Größe von 17 Bildern bei einer Bildgröße von 800 Pixel der Trainingsbilder. Neben der Erhöhung der Batch Size wird die Rechenzeit durch die verbesserte Grafikeinheit verkürzt, womit mehr Epochen in gleicher Zeit berechnet werden können.

#### 4.3.4 Analyse des Einflusses der Bildgröße und -auflösung

Zunächst wird der Einfluss der Bildgröße und -auflösung auf die Detektionsqualität näher untersucht. Die Modell Generation sieben wird für die folgende Auswertung betrachtet, da die anderen Modelle keine zielführenden Ergebnisse liefern. Modell 7 wird dreimal mit verschiedenen Bildgrößen von 800 bis 1600 Pixel trainiert. Die Modelle sind nach der Version und Bildgröße benannt, nämlich Modell 7.08, 7.12 und 7.16.

In der Mitte der **Abbildung 4.18** sind die Vorkommen der Objekte im zweidimensionalen Raum gezeigt. Die Objekte sind aufgrund der höheren Anzahl an Trainingsobjekten dichter gepackt. Die Verteilung der Klassen ist ausgeglichener als im Vorversuch, dennoch sind einige Klassen weniger vorhanden. Dem rechten Diagramm ist zu entnehmen, dass bis auf die Passfedern, die meisten Klassen eher höher sind als breit. Viele der Klassen befinden sich im Bereich der Marke von 0,1 relativer dimensionsloser Höhe und bis zu 0,05 dimensionsloser Breite. Im Balkendiagramm zur Häufigkeitsverteilung der Klassen haben sich die Klassennummern auf der Skala nach rechts verschoben und beginnen bei der Zahl drei.

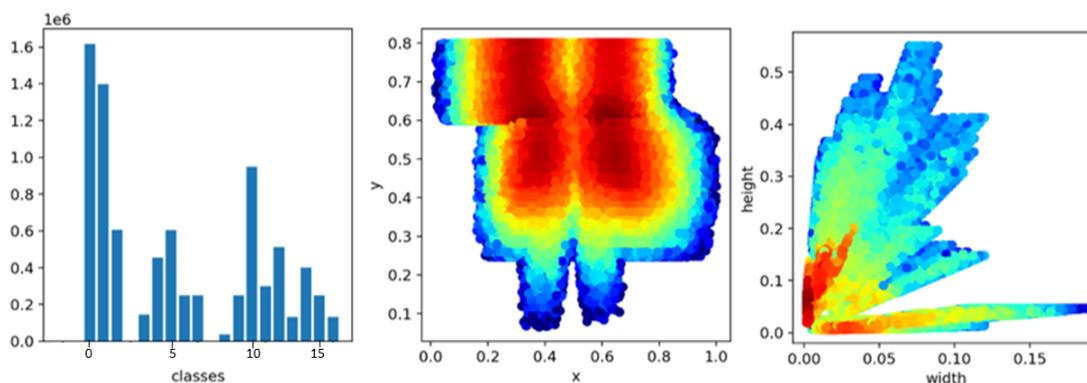


Abbildung 4.18: Verteilung der Klassen im Training bezüglich Modell 7.08 nach [Kra22]

Bei der Auswertung der folgenden Diagramme bzgl. der Modelle 7.08, 7.12 und 7.16 werden in den Graphen jeweils nur die letzten zehn Epochen des Trainings berücksichtigt, da es hier vor allem um die globalen Werte geht und nicht unbedingt um die Verläufe in Bezug auf das gesamte Training.

Zunächst wird das Modell mit Hilfe der **Abbildung 4.19** dargestellten Trainingsergebnisse analysiert. Die Präzision steigt bis Epoche 5 und nimmt dann wieder ab. Der Hochpunkt liegt bei 0,225. Der Recall legt dagegen stetig zu und beträgt maximal 0,6

anstatt 0,4 im Modell der Vorversuche. Die mAP-Werte steigen deutlich, sodass diese statt der 0,32 in den Vorversuchen einen Wert von 0,45 erreichen. Durch die Zunahme der Werte verbessert sich die Objektdetektion, obwohl die Präzision abgenommen hat. Anhand der Trainingsergebnisse ist zu erwarten, dass in realen Zeichnungen mehr richtige Markierungen gemacht werden, die Vorhersage zur Position und Größe der Objekte sich jedoch nicht verbessert hat.

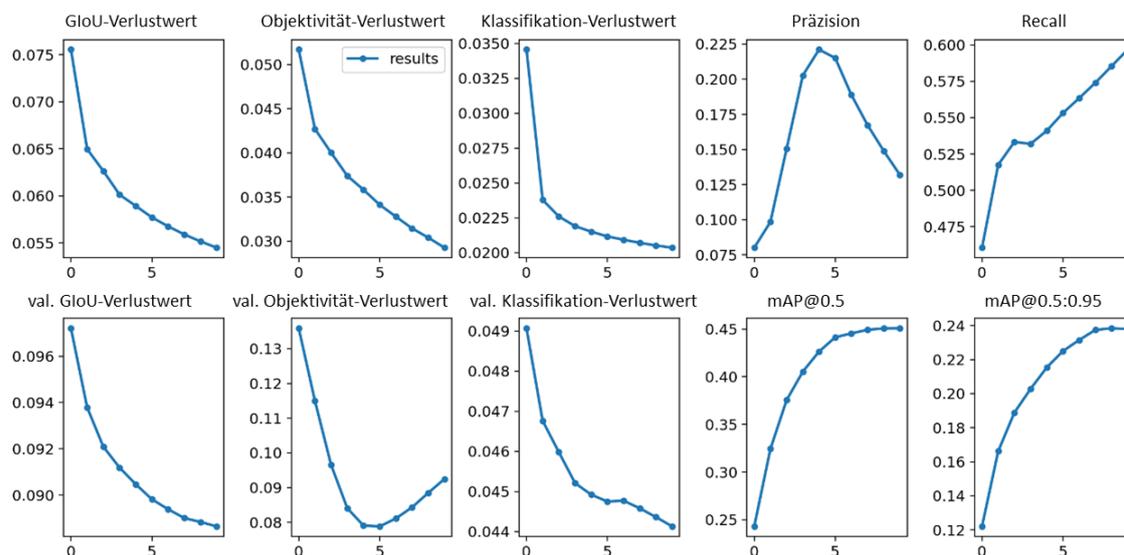


Abbildung 4.19: Trainingsergebnisse zu Modell 7.08 nach [Kra22]

Im Vergleich zu Modell 7.08 sehen die Diagramme in **Abbildung 4.20** zu Modell 7.12 sehr ähnlich aus. Sowohl die Verteilung der Klassen als auch die Verteilung der Objekte im Raum scheinen sehr ähnlich zu sein. Dies liegt daran, dass die statistische Verteilung der zufälligen Platzierung der Bauteile durch den Wellengenerator bei vielen Daten gleiche Ergebnisse liefert. Deshalb wird auf die Auswertung dieser Diagramme für das Modell 7.16 verzichtet.

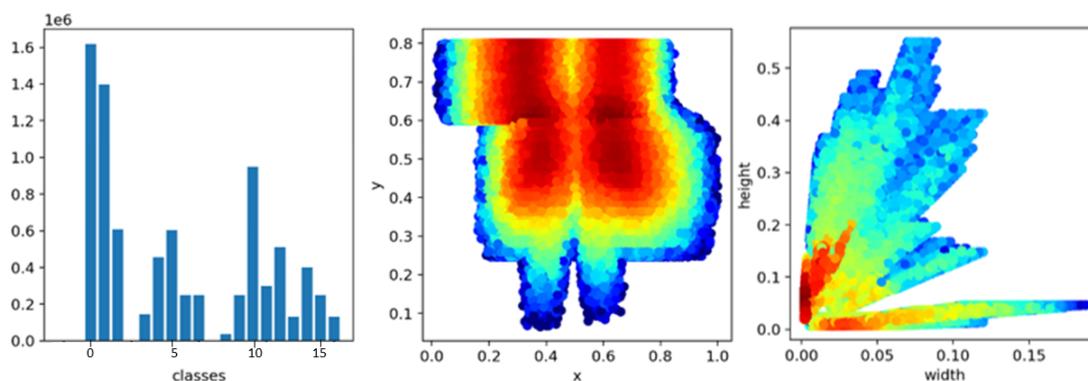


Abbildung 4.20: Trainingsergebnisse bezüglich Modell 7.12

Bei den Trainingsergebnissen, die in **Abbildung 4.21** visualisiert sind, zeigen sich kleine Unterschiede. Der GloU-Verlustwert nimmt ab, während die Präzision auf 0,3

zunimmt. Der Recall ist ebenfalls leicht erhöht und beträgt 0,66. Darüber hinaus hat sich die mAP-Wert auf 0,55 verbessert. Dass der GIoU-Verlustwert nimmt aufgrund der besseren Detailgenauigkeit mit zunehmender Bildgröße ab.

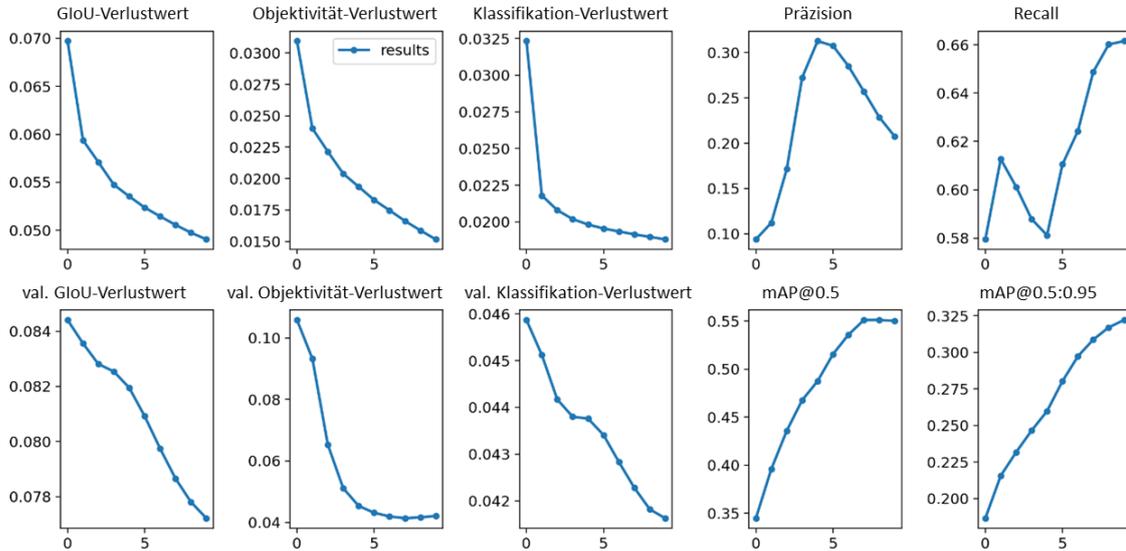


Abbildung 4.21: Trainingsergebnisse zu Modell 7.12

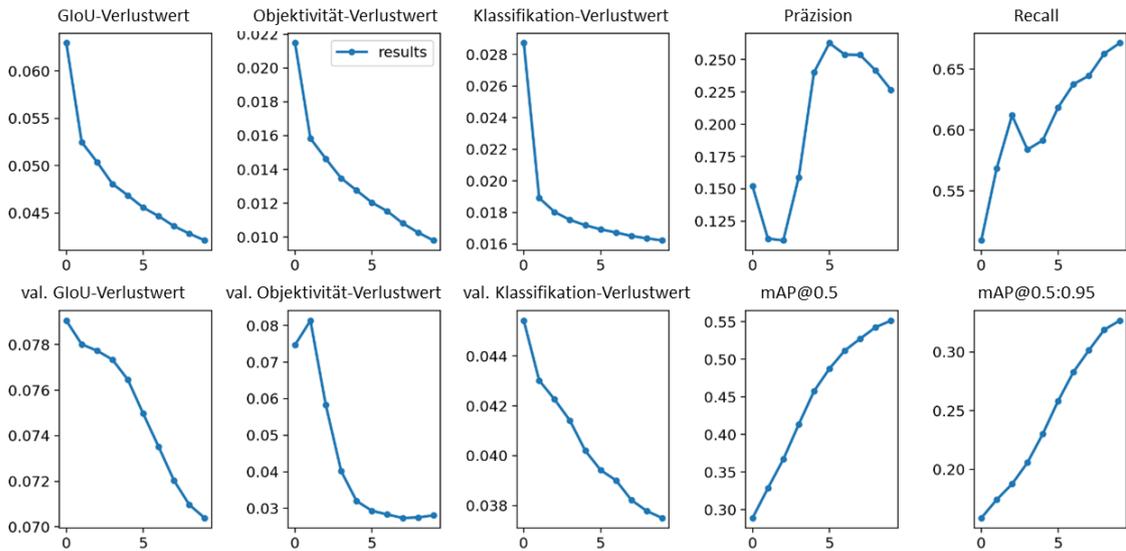


Abbildung 4.22: Trainingsergebnisse zu Modell 7.16

Die letzte Trainingsauswertung zu Modell 7.16 bestätigt den oben beschriebenen Trend (siehe **Abbildung 4.22**). Der GIoU-Verlustwert nimmt weiter leicht ab. Allerdings ist diese Abnahme seit dem ersten Modell gering im Vergleich zum absoluten Wert, welcher sich auf einem sehr geringen Niveau befindet. Demgegenüber nimmt die Präzision wieder ab und ist auf dem Niveau des Modells 7.08. Der mAP-Wert erreicht ebenfalls den Wert 0,55. Die Zunahme des Wertes bedeutet in diesem Fall, dass die falsch positiven Detektionen abnehmen und die falsch negativen zunehmen. Bei der Recall Kurve ist

jedoch zu erkennen, dass diese zunimmt, weshalb die falsch negativen Detektionen abnehmen. Gute GIoU-, Präzisions- und mAP-Werte liegen nahe bei eins, weswegen die Detektionsqualität nach dem Training als verbesserungswürdig eingestuft wird.

Insgesamt sind die Verlustwerte als gut zu bewerten, weil sie sich auf einem niedrigen Niveau befinden. Die Objektivität und die Übereinstimmung zwischen tatsächlichen Objektraum und der Detektion scheinen gut zu sein. Die Präzisions- und Recall-Werte sind als schwach zu bewertend, da sie im Intervallbereich von 0,2 bis 0,6 liegen.

Als nächstes wird die Detektionsgüte des Modells mit synthetischen Trainingsdaten anhand von Detektionen an synthetischen Zeichnungen ausgewertet (siehe **Abbildung 4.23**). Die meisten Detektionen sind korrekt gesetzt. Die BB weisen große Schnittmengen mit dem tatsächlichen Objektraum auf. Allerdings ist die Anzahl falsch negativer Ereignisse auffällig. Nicht erkannt werden Gewindeabsätze, der Freistich unter dem rechten Lager, die abtriebsseitige Fase, sowie die Wellenmutter mit Sicherungsblech. Wenn der Vertrauenswert für die Detektion erhöht wird, werden die soeben genannten Bauteile erkannt, jedoch nimmt die Anzahl der falsch positiven Erkennungen zu.

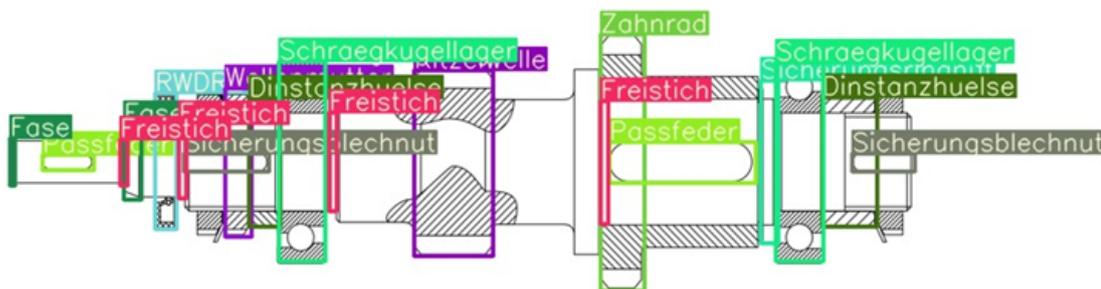


Abbildung 4.23: Detektionen an einem synthetischen Datensatz [Kra22]

In **Abbildung 4.24** ist eine technische Getriebezeichnung dargestellt, damit die Probleme der Erkennung in Bezug auf reale Zeichnungen deutlich werden. Die genauen Details können hier nicht erkannt werden, allerdings wird die Abbildung in der Form des Maßstabs 1:1 in die Arbeit integriert, um die Probleme der Objekterkennung von großen Zeichnungen herauszustellen. Anhand der Abbildung der DIN A0 Zeichnung kann begründet werden, warum die Neu-Definition der Klassen in dieser Form stattgefunden hat. In der Zeichnung des Maßstabs 1:1 werden ohne Fokus auf bestimmte Bildbereiche wesentlich weniger richtig positive und mehr falsch negative Ergebnisse erzielt. Es kann durch eine zweistufige Detektion die Effektivität und Qualität der Analyse verbessert werden, weil in der vorliegenden Zeichnung viele nicht interessante Bildbereiche mit verarbeitet werden. Darüber hinaus fällt bei der Analyse auf, dass nicht nur viele falsch positive und falsch negative Detektionen vorhanden sind, sondern

auch, dass die BB stärker von dem tatsächlichen Objektraum abweicht. Das Optimum des Vertrauenswertes liegt in diesem Fall bei 0,5.

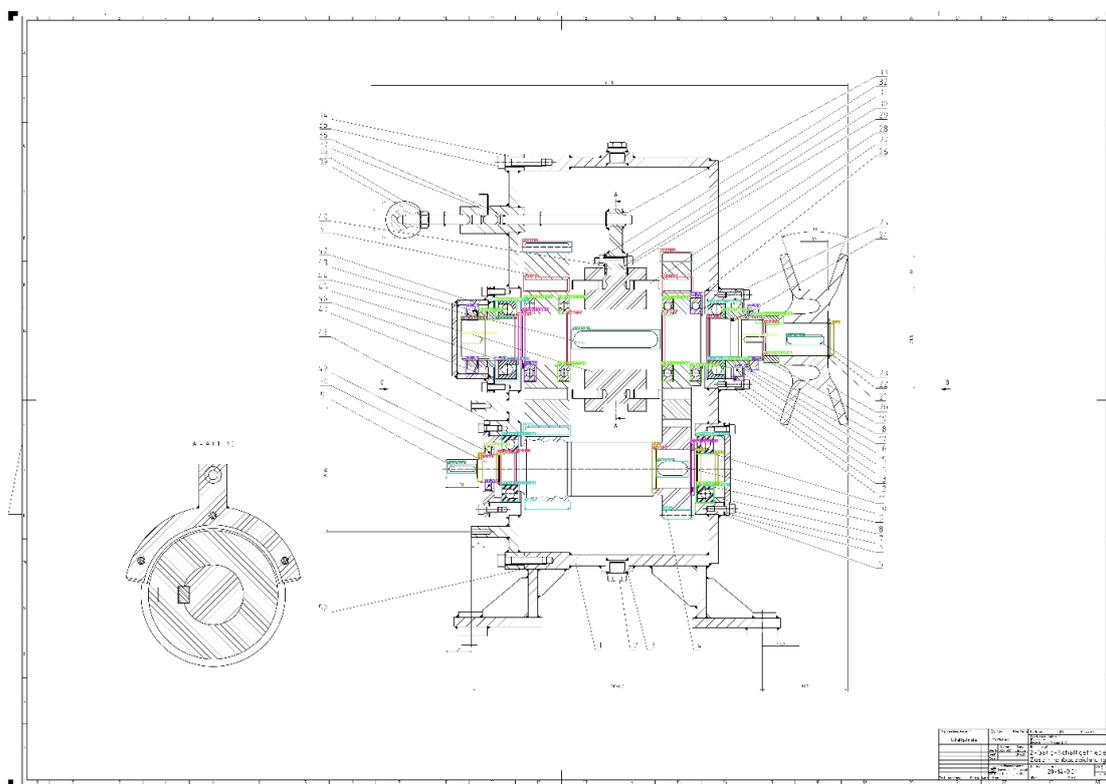


Abbildung 4.24: DIN A0 technische Getriebezeichnung nach [Sch21]

In Abbildung 4.24 festzustellen, dass die Mehrheit der Markierungen korrekt ist und keine falsch positiven Detektionen vorliegen. Trotzdem werden manche Bauteile nicht erkannt. Es liegen falsch negative Ergebnisse bezüglich der Wellenmutter an der dem Wellenende zu- sowie der abgewandten Seite vor. Wird der Vertrauenswert niedriger als 0,6 angesetzt, werden die Wellenmutter erkannt, jedoch nehmen dann auch die falsch positiven Detektionen zu. Die gesetzten BB sind als gut zu bewerten, weil sie sehr genau mit dem tatsächlichen Objektraum übereinstimmen. Es wird ein Anstieg des GIoU-Wertes erwartet.

Nach der oben angeführten Analyse werden die beiden Wellen in den **Abbildung 4.25** und **Abbildung 4.26** manuell vergrößert und geben den Ausschnitt der DIN A0 Zeichnung wieder. Diese sind repräsentativ für das Modell. Es werden Detektionen an den manuell ausgeschnittenen Bildern durchgeführt. Dennoch sind falsch positive und falsch negative Detektionen vorhanden, diese kommen aber weniger häufig vor. Dies betrifft das Rillenkugellager der Abtriebswelle unter dem rechten Zahnrad sowie den Freistich an der Ritzelwelle. Die Überschneidung der BB und des tatsächlichen Objektraums hat sich deutlich verbessert, kann bei einigen Klassen aber weiter verbessert werden. Ein Beispiel dafür ist die Wellenmutter auf der Abtriebswelle (siehe Abbildung 4.25) auf der dem Wellenende abgewandten Seite. Die Gewindeabsätze werden erkannt. In der

beschriebenen Abbildung werden die Klassen Wellenmutter sowie Wellenmutter und Sicherungsblech nicht zuverlässig erkannt.

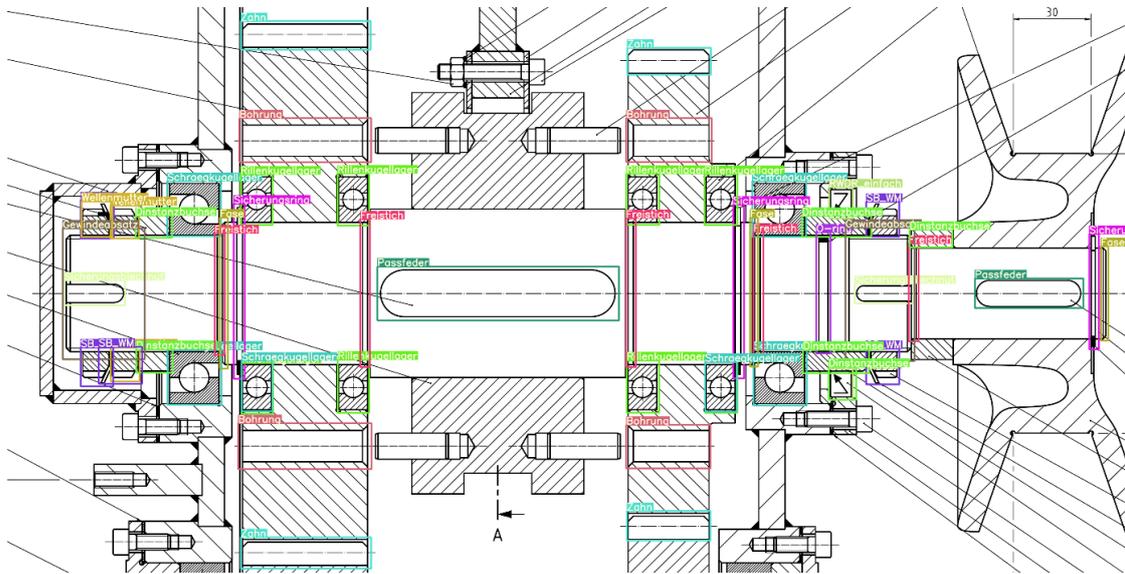


Abbildung 4.25: Detektionen an der Abtriebswelle nach [Sch21]

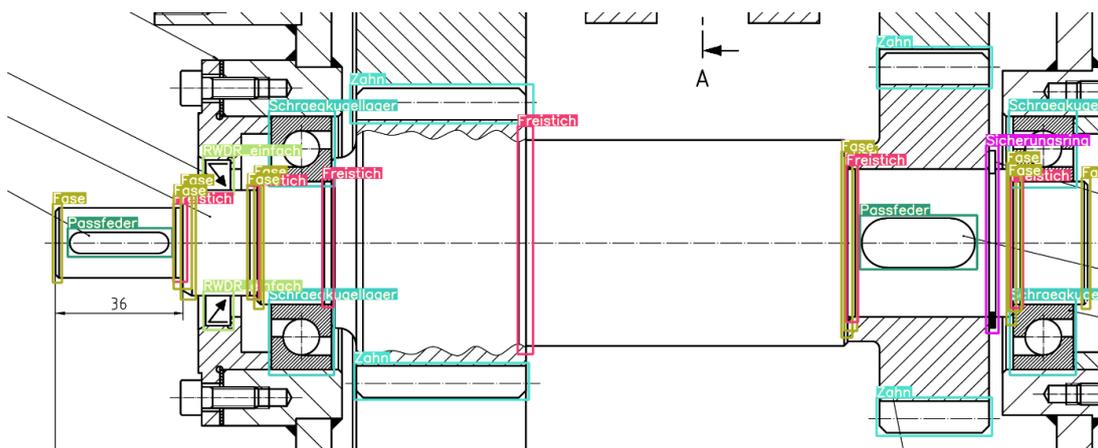


Abbildung 4.26: Detektionen an der Antriebswelle nach [Sch21]

Die Klassen werden möglichst präzise definiert, um wenig Überschneidungen und möglichst viele Merkmale pro Fläche zu erhalten und die Positionswiedergabe zu verbessern. Es zeigt sich, dass sich die Detektionsqualität durch die vergrößerte Darstellung der Objekte deutlich verbessert hat. Es werden sogar Klassen gut erkannt, welche nur wenig markante Merkmale aufweisen. Ein Beispiel dafür sind die erkannten Fasen und Freistiche in Abbildung 4.26. Die Güte der Erkennung der zuletzt genannten Klassen wird anhand von sich vom Trainings- und Testfall stark unterscheidenden Zeichnungen überprüft, damit sichergestellt werden kann, dass die Anwendung nicht nur für anwendungsnahe Probleme geeignet ist. Dies ist ein Hinweis darauf, dass sich die Einführung eines zweistufigen Detektionsalgorithmus als zweckmäßig erweisen kann.

In **Abbildung 4.27** ist ein Graph zu sehen, der den Anteil der Markierungen bezogen auf die Bildgröße veranschaulicht. Das Training wird mit Bildgrößen von 800, 1200 und 1600 Pixel durchgeführt, während die Größe der Detektionsbilder zur Überprüfung der Detektionsqualität zwischen Bildgrößen von 500 bis 3000 Pixel variiert wird. Die zuletzt genannte Bildgröße ist auf der Abszisse aufgetragen. Demgegenüber sind die prozentualen Markierungen auf der Ordinate aufgetragen. Diese können falsche (FP) und korrekte (TP) Markierungen beinhalten. Der Verlauf der angetragenen Punkte im Diagramm wird mit einer polynomischen Approximationskurve dritten Grades angenähert. Der Name des Modells steht für die Version vor dem Punkt und die Zahl nach dem Punkt für die Trainingsdaten in Pixel (z. B. 7.08 bedeutet Version 7, trainiert mit einer Bildgröße von 800 Pixel).

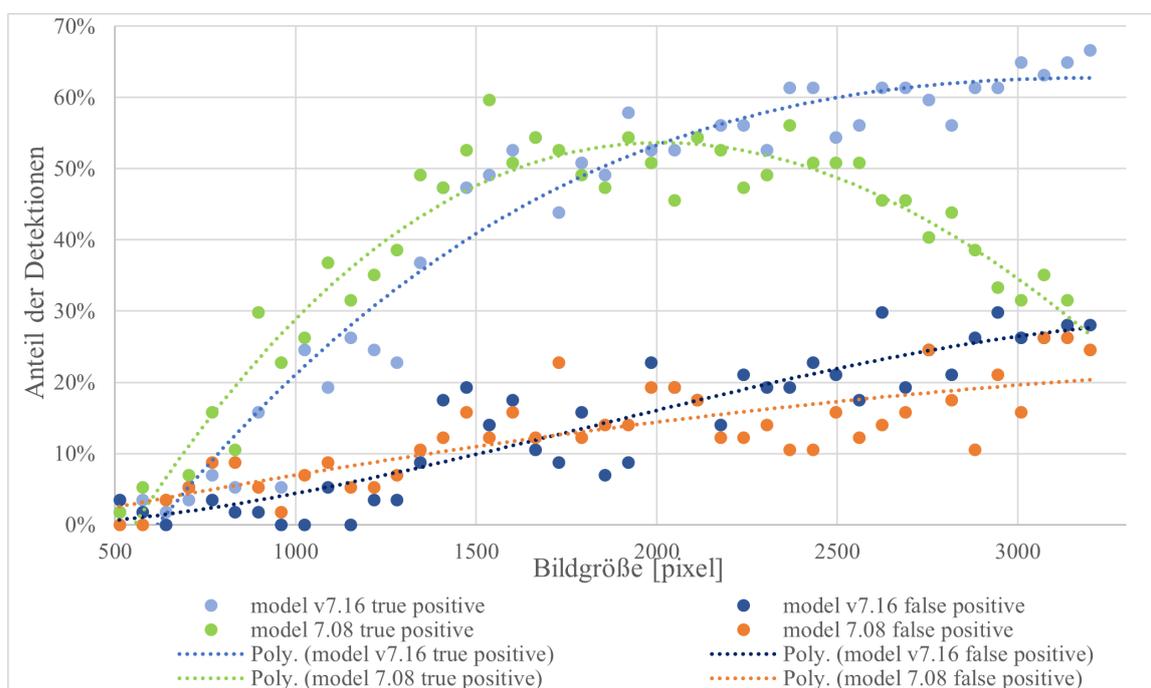


Abbildung 4.27: Abhängigkeit der Erkennungen von der Bildgröße nach [Dil23a]

Die Bildgröße auf der Abszisse bezieht sich auf die tatsächliche Eingabe von realen TZ, auf denen der ODA die Erkennungen markiert. Der Prozentsatz wahrer positiver Erkennungsklassen steigt für beide Modelle bis zu einer Bildgröße von etwa 2000 Pixel an. Anschließend fällt der Verlauf des Modells, welches mit einer Bildgröße von 800 Pixel trainiert wird, ab, während der Verlauf des anderen Modells weiter wächst.

Bei beiden Modellen ist ein linearer Anstieg der falsch positiven Erkennungen mit zunehmender Bildgröße festzustellen. Wenn das zu prüfende Bild eine hohe Bildgröße besitzt, ist die Wahrscheinlichkeit falsch positiver Erkennungen größer. Falsch positive Erkennungen treten seltener bei Klassen auf, die einzigartige Merkmale aufweisen, wie z. B. die Darstellung des Aufbaus eines Radialwellendichtrings. Eine höhere Bildgröße in Bezug auf die Trainingsdaten bietet bessere Möglichkeiten, die Erkennungsqualität

für hochauflösende Bilder in Bezug auf TZ zu erhöhen, wenn eine einstufige Detektion verwendet wird.

In Bezug auf die Bildgröße wird das folgende Ergebnis festgehalten. In TZ, die ein Format von bis zu DIN A0 aufweisen, gehen für die zuverlässige Erkennung wichtige Merkmale aufgrund der Verkleinerung des Bildes verloren. In einer umfangreichen Getriebezeichnung können Bildgrößen von 9600 Pixel bei DIN A0 Zeichnungen vorliegen. Dies entspricht einer Scanauflösung von 300 dpi (dots per inch). Wird das Bild bspw. auf 800 Pixel verkleinert, dann können einige Details nicht mehr vernünftig dargestellt werden. Bei einer Größe der DIN A0 Zeichnung von  $841 \times 1189$  mm und einer Bildgröße von 800 Pixel, entspricht ein Pixel mindestens einem Millimeter. Bei einer Bildgröße von 9600 Pixel ist ein Pixel etwa 0,12 mm groß. Dies entspricht einer Verschlechterung der Auflösung um eine Zehnerpotenz. Laut dem in Abbildung 4.27 abgebildeten Graphen werden bei einer Bildgröße der im Training verwendeten Bilder von 800 Pixel maximal 50% der Objekte richtig erkannt. Größere Bildgrößen haben demnach ein größeres Potential eine höhere Detektionsqualität zu erreichen. Daher können entweder die Bildgröße verbessert oder die Objekte fokussiert werden. Da eine größere Bildgröße für den Input in *YOLO* nicht empfehlenswert ist, wird das zweite Vorgehen verfolgt.

Da die gesamte Untersuchung auf *YOLOv4* beruht, wird der Algorithmus manuell auf einen zweistufigen Detektor umgestellt, indem initiale Detektionen genutzt werden, um ROIs festzulegen. Damit der Detektor trotzdem effizient bleibt, wird die Anzahl und Größe der ROIs begrenzt. Eine Konzentration soll auf Wellenebene statt auf Bauteilebene stattfinden, sodass die Detektion im ersten Schritt Wellenbaugruppen erkennt. Danach wird alles um die Bauteile, die sich auf der Welle befinden, ausgeschnitten. Damit werden pro Zeichnung zwei bis sechs ROIs festgelegt. Auf die Möglichkeit der Nutzung eines bestehenden zweistufigen Detektionsalgorithmus aus der Literatur wird verzichtet, um die weiteren Ergebnisse mit den im Verlaufe dieser Arbeit erarbeiteten Ergebnisse besser vergleichen zu können.

## 4.4 Analyse und Auswertung der zweistufigen Modelle

In diesem Unterkapitel werden die zweistufigen Modelle der KI-Detektion analysiert, welche mit synthetischen, manuellen und gemischten Trainingsdaten angelernet werden. Ein teil-faktoriell ausgelegter Versuchsplan wird zu dem Zweck erstellt, die Detektionsqualität anhand der verfügbaren Stellschrauben zu optimieren (siehe **Tabelle 4.4**). Falls im weiteren Verlauf von einem Standard der Detektionseinstellungen die Rede ist, dann werden der Vertrauenswert auf 0,4 und der IoU-Schwellenwert auf 0,2 festgesetzt. Diese Parameter werden teilweise konstant gehalten, um andere Einflüsse und Parameter zu

testen. Es wird eine Verteilung der Bilddaten zu Anteilen von 70-80% für das Training, 10-20% für die Validierung und 10% für das Testen der KI-Detektion angewendet.

Tabelle 4.4: Versuchsplan zu den Versuchen des zweistufigen Detektors

	<b>Training</b>	<b>Detektion</b>
<b>Manuell</b>	800 px: 400 Zeichnungen	800 px: SW=[0,3;0,4;0,5;0,6] und IoU=[0,2;0,5] 1200 px: SW=0,4 und IoU=0,2
	1200 px: 400 Zeichnungen	800 px: SW=0,4 und IoU=0,2
<b>Synthetisch</b>	800 px: 10.000 Zeichnungen	800 Pixel: SW=0,8 und IoU=0,2
<b>Gemischt</b>	800 px: 10.400 Zeichnungen	800 px: SW=0,25 und IoU=0,2
	1200 px: 5400 Zeichnungen	800 px: SW=0,25 und IoU=0,2

#### 4.4.1 Auswertung des manuellen zweistufigen Modells

In diesem Abschnitt wird das Modell des zweistufigen Detektors ausgewertet, dessen Trainingsdaten manuell gelabelt werden. 400 Zeichnungen werden als Trainingsdaten verwendet. Die Bildgröße beträgt 800 Pixel, was zu einer maximalen Batch Size von 17 Bildern bei einem verfügbaren Videospeicher von 24 GB VRAM führt (siehe **Tabelle 4.5**). Die Bilder mit der genannten Bildgröße repräsentieren das Bild einer zurechtgeschnittenen Welle aus der gesamten Getriebezeichnung. Der erste Schritt des zweistufigen Detektionsalgorithmus wird so eingeführt, als dass zunächst Wellen erkannt werden sollen. Die gefundene Welle wird aus der Getriebezeichnung ausgeschnitten und auf eine Größe von 800x800 Pixel umgewandelt.

Tabelle 4.5: Trainingsdaten zum zweistufigen manuellen Detektionsmodell

Trainingsparameter	Werteintervall
Batch Size	17 Bilder
Bildgröße	800 px
Epochen	Bis zu 250
Anzahl der Trainingsbilder	400
GPU	<i>NVIDIA RTX 3090 Ti</i> (24 GB VRAM)
Anteil Validierungsdaten	10-15% der Trainingsbilder

Die Detektion der Wellen funktioniert zuverlässig, wenngleich falsch positive Ergebnisse ausgegeben werden. In einer Getriebezeichnung mit zwei Hauptwellen und einer kleinen Schaltgabelwelle werden drei bis fünf Wellen erkannt. Der dargestellte Ausschnitt ist so gewählt, dass die Zähne der Zahnräder und das Ende der Wellen den Bildausschnitt

begrenzen. Dieser Ausschnitt erhöht die Detektionsqualität enorm, weil die Objekte bei gleicher Bildgröße in etwa um das zwei- bis achtfache vergrößert dargestellt werden.

Weiterhin ergeben sich bei den Trainingsergebnissen laut **Abbildung 4.28** verbesserte Werte. Die Verlustwerte bezogen auf GIoU, Objektivität und Klassifikation sind auf einem ähnlichen Niveau mit leicht verbesserter Tendenz. Besonders gestiegen ist der Präzisionswert, welcher einen Zahlenwert von 0,6 erreicht. Der Recall steigt auf einen Wert von 0,8 an. Dies entspricht einer Verbesserung von rund 20%. Der mAP0.5-Wert erhöht sich von 0,55 auf 0,8. Der mAP0,5:0,95-Wert steigt ebenfalls an. Hier sind jedoch erhöhte Schwankungen zu verzeichnen. Dies kann darauf hinweisen, dass das Training durch die geringe Anzahl an Trainingsdaten nicht immer in die gewünschte Richtung läuft. Die Anpassung der Gewichtungen im NN kann in diesem Fall die Qualitätswerte abmildern. Dadurch wird das neuronale Netz in manchen Phasen des Trainings zu Ungunsten der in Abbildung 4.28 gezeigten Kennwerte angepasst. Darüber hinaus weisen die steigenden Verläufe der Validierung bezüglich GIoU, Objektivität und Klassifikation ab Epoche 100 auf ein potentielles Übertraining (overfitting) hin.

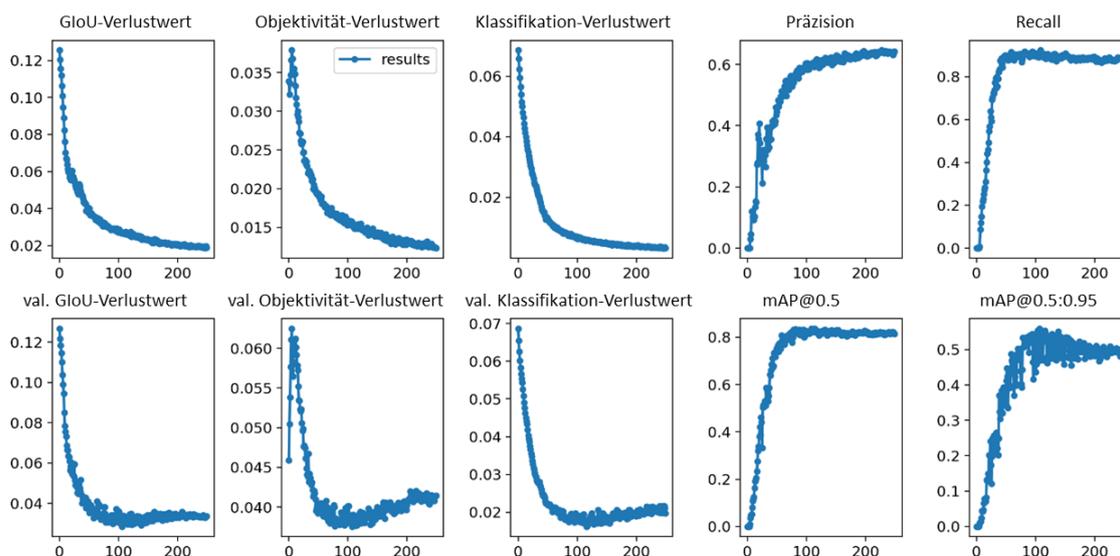


Abbildung 4.28: Trainingswerte des zweistufigen manuellen Modells

Als nächstes werden die Detektionen an realen Zeichnungen ausgewertet. Die **Abbildungen 4.29 und 4.30** zeigen eine reale Zeichnung (Welle in der Mitte geschnitten), die repräsentativ für das Gesamtergebnis ist. Es handelt sich hierbei um eine Antriebswelle, dessen Anzahl an auf der Welle befindlichen Bauteilen im Gegensatz zu den Abtriebswellen in diesem Beispiel geringer ist. Die Abmessungen dieser Welle sind kleiner, weshalb Bauteile innerhalb einer bestimmten Bildgröße größer dargestellt werden können. Alle angelernten Klassen werden in dieser Abbildung richtig erkannt und detektiert. Erkannt werden Rillenkugellager, Ritzelwelle, Zähne, Passfeder, Sicherungsringe und Radialwellendichtringe. Die BB stimmen mit den realen Bauteilen relativ

genau überein. Einzig bei der Ritzelwelle und den Sicherungsringen sind die BB größer als die Bauteilabmessungen, resultierend aus der Definition der Labelgröße, weil diese Markierungen mit einem großzügigen Offset versehen wurden.

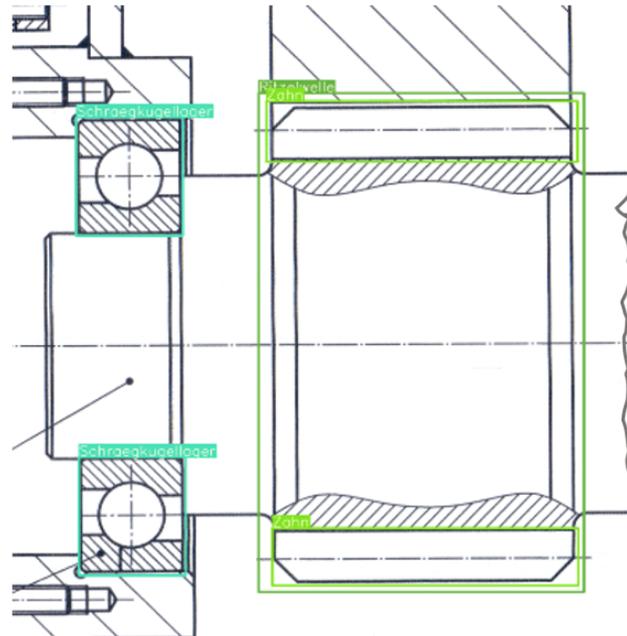


Abbildung 4.29: Detektionen an einer Antriebswelle durch das manuelle Modell (I)

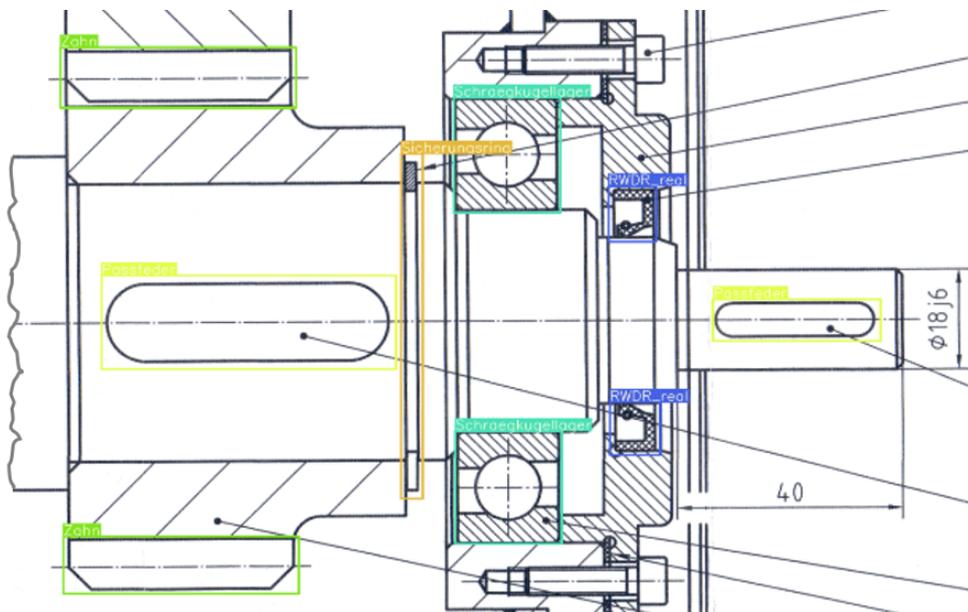


Abbildung 4.30: Detektionen an einer Antriebswelle durch das manuelle Modell (II)

Die Detektion wird mit einem Vertrauenswert von 0,4 und einer IoU-Schwelle von 0,2 durchgeführt. Die Gewichtung aus Epoche 150 des Trainings wird für die Erkennung verwendet. Es wird darauf hingewiesen, dass Trainingsdaten nicht gleichzeitig für Validierung und Test verwendet werden sollten. Auf diese Trennung wird innerhalb dieser

Arbeit stets Wert gelegt. Die Validierung ist in diesem Zusammenhang die Auswertung des Algorithmus bezüglich des Trainings, wie die Ergebnisse in Abbildung 4.28 zeigen. Es wird der Begriff Testdaten verwendet, um den Detektionsalgorithmus anhand von Zeichnungen manuell zu überprüfen. Dies geschieht, indem ein ausgeglichener Pool an Zeichnungen ausgewählt wird, und anhand dieses Datensatzes die richtig positiven, falsch positiven und falsch negativen Detektionsergebnisse ausgewertet werden, sodass die Qualitätsparameter berechnet werden können.

Die in **Tabelle 4.6** dargestellten Werte der Wahrheitsmatrix bestätigen den Trend der Trainingsergebnisse. Es werden 24 Zeichnungen begutachtet und der arithmetische Mittelwert aus den unten angegebenen Werten ermittelt. Die 24 Testzeichnungen beinhalten zwölf Antriebs- sowie zwölf Abtriebswellen. Durchschnittlich werden 95,51% der Bauteile richtig positiv erkannt. Ein geringer Anteil von 0,43% wird nicht erkannt, obwohl die Klasse im Bild vorhanden ist. 4,06% der Markierungen sind falsch positiv detektiert worden. Dies bedeutet, dass der Algorithmus Detektionen bzw. Markierungen einer Klasse gesetzt hat, die sich an dieser Stelle nicht befinden.

Tabelle 4.6: Wahrheitsmatrix mit den Werten zum manuellen Training

Objekt- erkennung	Realität		
	Erkennung	Ja	Nein
Ja		95,51%	0,43%
Nein		4,06%	-

Im vorherigen Abschnitt wurden die Gesamtergebnisse der Detektion dargelegt. Eine Auswertung der Detektionsergebnisse bezogen auf die Güte der jeweiligen Klassen ist interessant, um diese bewerten zu können. Dazu ist in **Abbildung 4.31** ein Diagramm abgebildet, welches die Verlustrate, die Präzision, den Recall und die globale Genauigkeit in Bezug auf die einzelnen Klassen abbildet. Die betrachteten Klassen sind auf der Abzisse und die prozentualen Werte auf der Ordinate angetragen. Der Verlauf des Recalls (blaue Linie) ist dicker dargestellt, weil diese mit dem Verlauf der globalen Genauigkeit (rote Linie) oftmals übereinstimmt und diese Verläufe so besser zu unterscheiden sind. Die Ergebnisse sind in den folgenden Abschnitten jeweils aufgrund der Übersichtlichkeit mit Hilfe eines Balkendiagramms visualisiert, weil die Klassen nominal skaliert sind.

Unter dem Diagramm befindet sich eine Tabelle mit den dazugehörigen Werten. Die Klasse RWDR weist eine Verlustrate von 0,119 und einen Recall von 0,881 auf. Dies weist darauf hin, dass falsch negative Ergebnisse vorliegen. Es werden nicht alle Bauteile dieser Klasse auf der Welle erkannt. Im Gegenzug beträgt die Präzision 100%, sodass keine falschen Markierungen durch den Algorithmus gesetzt werden. Dies führt insgesamt zu einer globalen Genauigkeit von 0,881. Bei der Klasse Wellenmutter hingegen liegen falsch

positive Ergebnisse vor. Die Präzision beträgt 0,9167. Falsch positive Ergebnisse ergeben sich in Verbindung mit Wellenmuttern mit Sicherungsblech oder Distanzbuchsen, die sich häufig direkt neben diesem Bauteil befinden. Dies führt zu einer globalen Genauigkeit von 0,9167, weil keine falsch negativen Detektionen vorkommen.

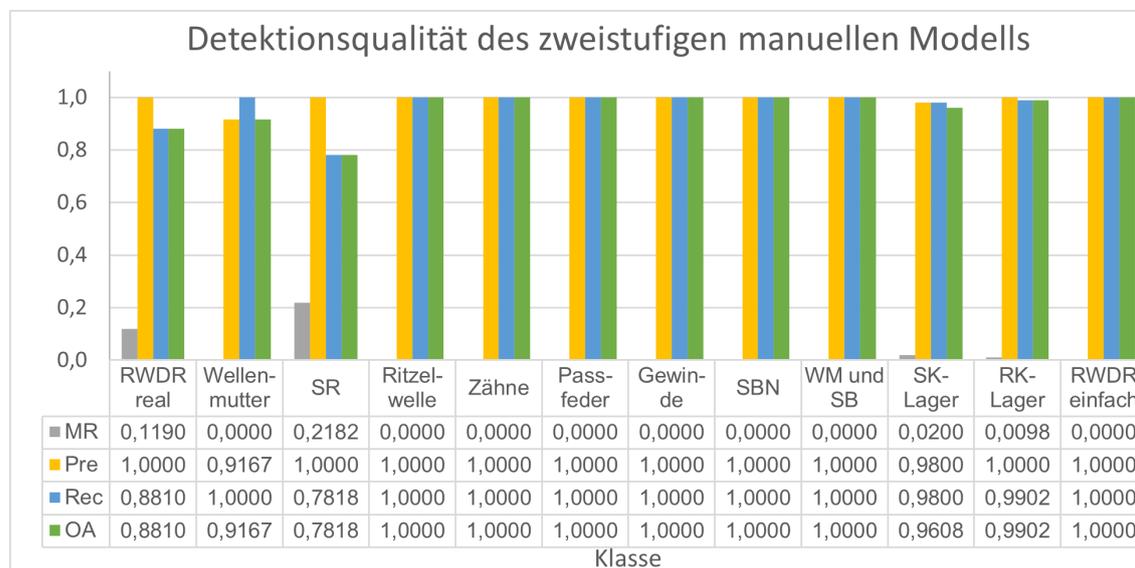


Abbildung 4.31: Diagramm der Qualitätsparameter Verlustrate, Präzision, Recall und globale Genauigkeit

Die Klasse Sicherungsring erreicht die höchste Verlustrate und den niedrigsten Genauigkeitswert. Das liegt daran, dass Sicherungsringe häufiger nicht durch den Detektionsalgorithmus erkannt werden. Damit erzielt diese Klasse eine globale Genauigkeit von 0,7818. Die weiteren Klassen erreichen globale Genauigkeiten von mehr als 0,98, weshalb diese Erkennungsqualität als gut eingestuft werden kann. Bei den Klassen der verschiedenen Lager treten teilweise Verwechslungen auf, weil sich Schrägkugellager und Rillenkugellager sehr ähneln. Es kommt selten von, dass ein Lager nicht erkannt wird. Es werden auch Lager erkannt, bei denen die Mittellinie fehlt. Die Detektion von Bauteilen auf Antriebswellen funktioniert zum Teil zuverlässiger im Vergleich Objekten auf Abtriebswellen. Diese unterscheiden sich durch die Häufigkeit der Vorkommen der Klassen in einem Bild, sowie der geringfügig vergrößerten Bauteile in einem Bild gleicher Auflösung und Größe. Deshalb wird in der weiteren Auswertung überprüft, woraus dieser Unterschied resultiert. Es handelt sich insgesamt um sehr kleine Unterschiede, da sich die Detektionsqualität von Antriebs- und Abtriebswelle auf einem ähnlichen Niveau befindet.

#### 4.4.2 Auswertung des zweistufigen synthetischen Modells

Nachdem der Algorithmus zu Anfang für Bilder mit zwei Wellen programmiert wurde, um automatisch generierte Zeichnungen zu erstellen, wird eine Umstellung vorgenom-

men, welche repräsentativ in **Abbildung 4.32** zu sehen ist. Nachdem sich in den Vorversuchen die Entwicklung eines zweistufigen Detektors hervorgetan hat, ist es sinnvoll die Erstellung von Trainingsdaten auf die Ebene einer Welle zu beschränken, um möglichst qualitativ hochwertige Trainingsdaten erstellen zu können.

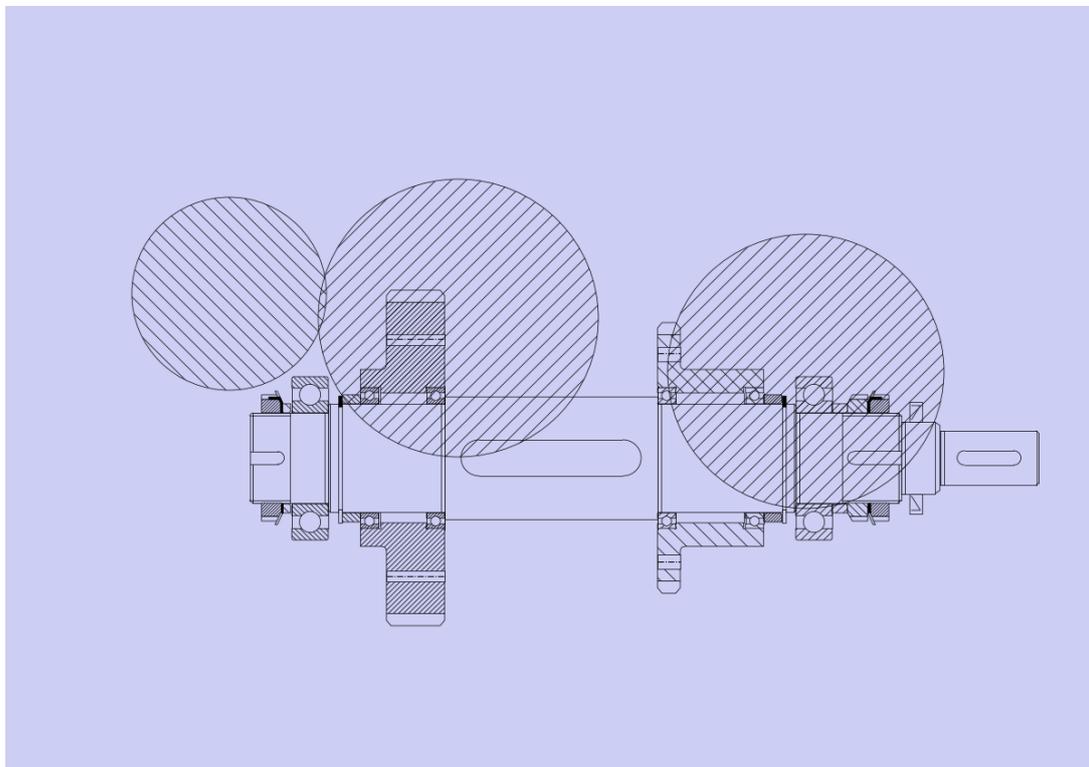


Abbildung 4.32: Automatisch generierte Zeichnung des angepassten Wellengenerators

Daher wird in der weiteren Entwicklung auf einen automatischen Generator hingearbeitet, welcher eine Welle erstellt. Es werden abwechselnd An- und Abtriebswellen automatisch erstellt. Hinzu kommen Farbveränderungen, die in der Abbildung 4.32 deutlich zu sehen sind. Neben der Skalierungsunabhängigkeit soll so eine gewisse Beleuchtungsunabhängigkeit erreicht werden, weil eingescannte Zeichnungen farbliche Unterschiede aufweisen können. Es ist außerdem deutlich feststellbar, dass die Zeichnung deutlich besser aufgelöst wird als die Zeichnung in Abbildung 4.15, da die Objekte bei gleicher Auflösung und Größe in etwa doppelt so groß dargestellt werden können. Außerdem werden die Störfaktoren randomisiert und werden innerhalb von Kreisen eingezeichnet.

Die neuen Trainingsparameter zum synthetischen Modell sind in **Tabelle 4.7** aufgelistet. Die Anzahl der Trainingsbilder kann durch den automatischen Wellengenerator auf 10.000 erhöht werden. Außerdem können einfach neue Validierungsdaten erstellt werden, die ungleich der Trainingsdaten sind. Die Anzahl der Epochen wird aufgrund der vorherigen Erfahrungen auf 200 gesetzt. Sollte dies nicht ausreichen, kann durch einen *resume*-Befehl das Training fortgesetzt werden. Dabei werden die Gewichtungen in

zehner-Epochenschritten vom Start des Trainings an gespeichert, sowie die letzten 10 Epochen.

Tabelle 4.7: Übersicht der für das synthetische Training genutzten Parameter

Trainingsparameter	Werteintervall
Batch Size	17 Bilder
Bildgröße	800 px
Epochen	200
Anzahl der Trainingsbilder	10.000
GPU	<i>NVIDIA RTX 3090 Ti</i> (24 GB VRAM)
Anteil Validierungsdaten	10% der Trainingsbilder

Die Trainingsergebnisse des synthetischen Trainings sind auf einem hohen Niveau (siehe **Abbildung 4.33**). Recall- und Präzisionswerte erreichen approximativ den Höchstwert eins. Die Präzision erreicht Werte über 0,8. Die Verlustwerte sind als sehr gering einzustufen. Das Anlernen wird 200 Epochen lang durchgeführt. Für die Detektion bieten sich laut der Diagramme Gewichtungen aus Epoche 150 an, weil ab hier die Verlustwerte teilweise wieder ansteigen. Größere Unterschiede ergeben sich bei der Detektion. Hier muss ein hoher Vertrauenswert von 0,8 gewählt werden, damit nicht zu viele falsch positive Ergebnisse vorkommen. Auf der anderen Seite wird durch diese Einstellung der Anstieg der Anzahl falsch negativer Ergebnisse begünstigt. Es ist ein Indikator dafür, dass die Qualitätsparameter gehemmt sein werden.

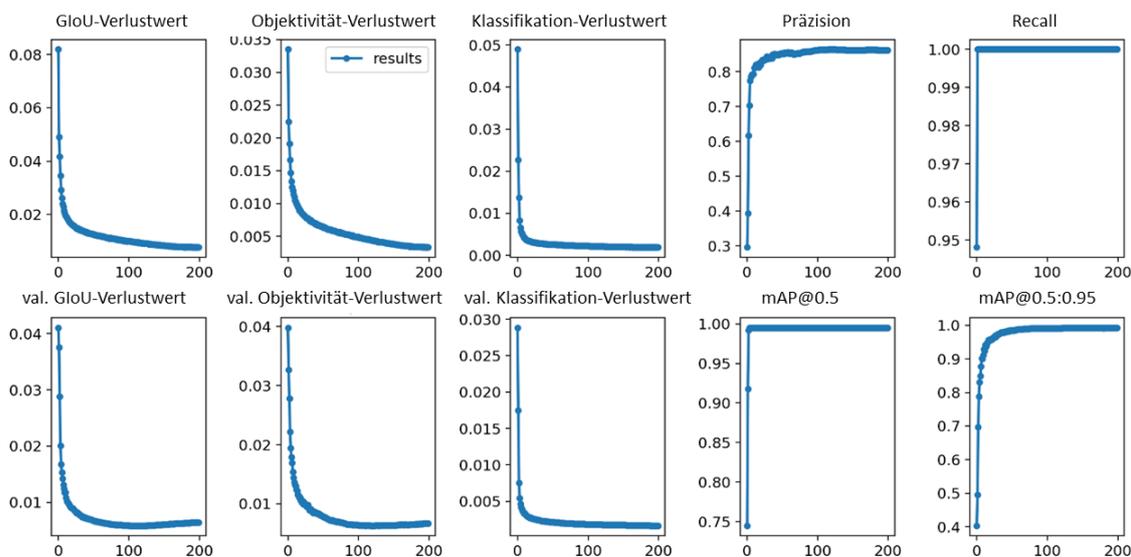


Abbildung 4.33: Trainingswerte zum synthetischen KI-Modell

Die in **Tabelle 4.8** abgebildete Wahrheitsmatrix zeigt die prozentualen Anteile der Detektionen an realen Zeichnungen. 30,92% der Detektionen sind richtig positiv. Ein

größerer Anteil von 40,67% sind Markierungen, die falsch gesetzt werden. In den BB befindet sich in der Realität nicht das vorhergesagte Bauteil. Es treten häufig Fälle auf, in denen die Klasse Wellenmutter mit Sicherungsblech sowie die Klasse RWDR\_real durch den Detektor vorhergesagt wird, die Bauteile sich an diesen Stellen jedoch nicht befinden (siehe **Abbildung 4.34**).

Tabelle 4.8: Wahrheitsmatrix zum synthetischen KI-Modell

Objekt- erkennung	Realität		
	Erkennung	Ja	Nein
Ja		30,92%	40,67%
Nein		28,41%	-

In der genannten Abbildung ist außerdem zu sehen, dass Bauteile nicht erkannt werden. Dies betrifft Zähne und Lager. Deshalb ist der Anteil nicht erkannter Objekte mit 28,41% ebenfalls recht hoch. Zusammenfassend ist der Anteil von  $\frac{1}{3}$  erkannter Bauteile als niedrig zu bewerten. Darüber hinaus treten sehr viele falsche Markierungen auf. Für den potentiellen Einsatz in der Lehre ist dies nachteilig. Wird der Vertrauenswert der Detektion herabgesetzt, verringern sich die falsch positiven Ereignisse, jedoch werden viel mehr vorhandene Bauteile nicht mehr erkannt, weshalb die Rate an falsch negativen Detektionen stark zunimmt.

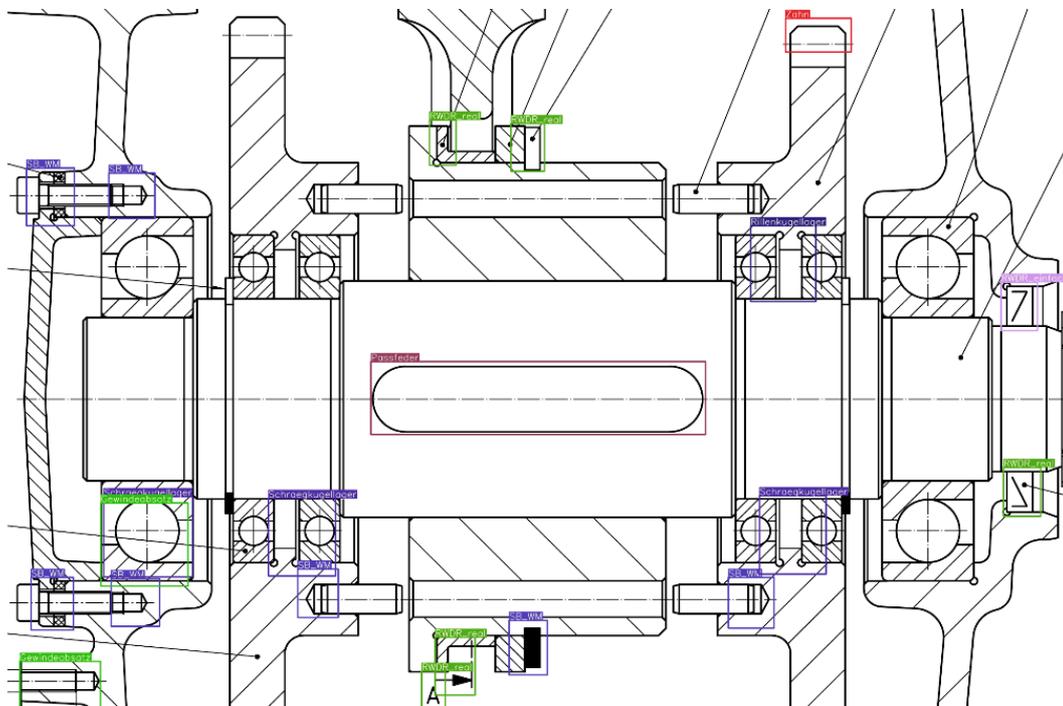


Abbildung 4.34: Detektionen des synthetischen Modells nach [Lat21]

In Abbildung 4.34 sind nicht nur Verwechslungen von Bauteilen vorhanden, wie z. B. die Erkennung eines realen RWDR, obwohl nur eine vereinfachte Darstellung

vorliegt, sondern auch Markierungen, die sich nicht logisch erklären lassen. So werden bspw. an dem Schnitt mit dem Kennbuchstaben A zwei RWDR erkannt, obwohl keine Ähnlichkeiten vorliegen. Dies betrifft auch die Detektionen bezüglich der Wellenmutter mit Sicherungsblech.

Anhand der Klassenauswertung, welche in **Abbildung 4.35** dargestellt ist, lassen sich interessante Schlussfolgerungen ziehen. Zähne, Passfedern und vereinfacht dargestellte RWDR weisen keine oder wenig falsch positive Detektionen auf, werden allerdings wegen des hoch angesetzten Vertrauenswertes nicht gefunden. Auffällig ist auch, dass die Klassen Ritzelwelle und Sicherungsring nicht einmal erkannt werden. Bei der Ritzelwelle tritt es aufgrund des fehlenden zweiten Zahnrades des Zahnradpaares auf. Es erschließt sich jedoch nicht, warum kein Sicherungsring erkannt wird. Es liegen zwar nur wenige Merkmale innerhalb dieser Klasse vor, allerdings wird diese Klasse im vorherigen manuellen Modell zuverlässiger erkannt. Am besten können Wellenmutter, Wellenmutter mit Sicherungsblech und Passfedern erkannt werden und erreichen globale Genauigkeiten von mehr als 0,6. Die Werte bezüglich der Klassen Zähne, Gewindeabsätze und Rillenkugellager befinden sich auf einem Niveau von etwa 0,5 globaler Genauigkeit.

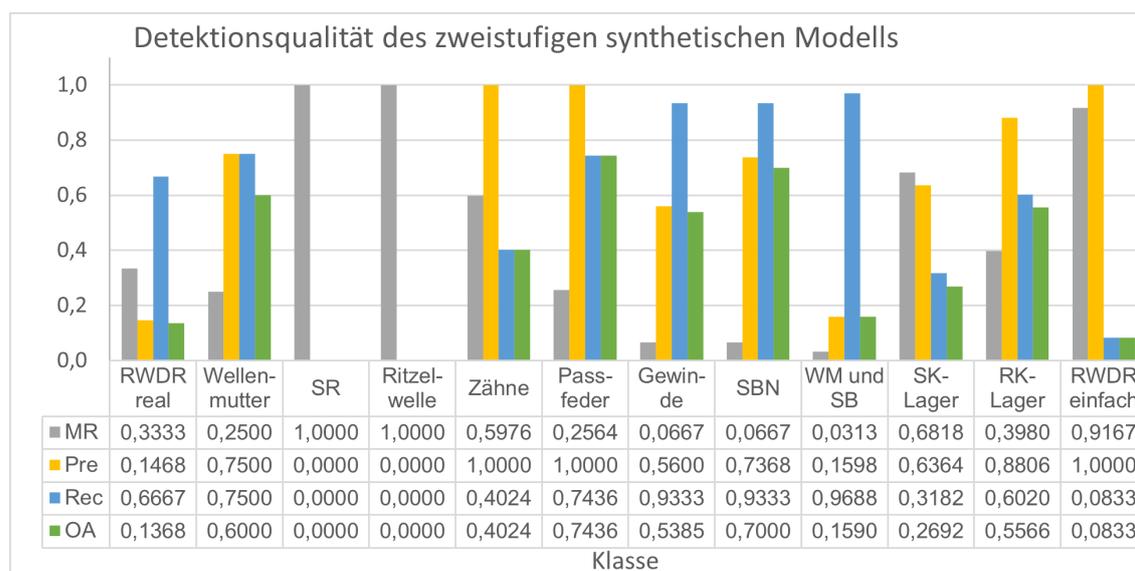


Abbildung 4.35: Klassenauswertung zum synthetischen Modell

Demgegenüber werden Schrägkugellager sehr viel schlechter erkannt und erreichen eine globale Genauigkeit von 0,2692. Alle Detektionsergebnisse befinden sich auf einem niedrigen oder sehr niedrigen Niveau. Im Vergleich zum manuell trainierten Modell ist die Detektionsqualität deutlich schlechter, obwohl mehr Trainingsdaten zur Verfügung stehen und ein automatisiertes Labeln stattgefunden hat. Die synthetisch erzeugten Daten bilden die realen Daten nicht sehr genau ab. Die Bauteile sind an und für sich die gleichen wie in den realen Zeichnungen und weisen zumeist die gleiche Größe auf, weil die Mehrzahl der Bauteile genormt sind. Die Auswertung hat gezeigt, dass die Störgrößen

dafür sorgen, dass die Qualitätswerte stark herabgesetzt werden und Klassen aufgrund der vorhandenen eingefügten Linien nicht erkannt werden. Daher bietet es sich an, das synthetische Modell ohne Störeinflüsse erneut zu erstellen und die Detektionsqualität wiederholt testen. Es wird jedoch vermutet, dass die Güte der Ergebnisse niemals die des manuellen Modells erreichen wird.

Insgesamt lässt sich die Detektionsqualität durch die Erstellung synthetischer Trainingsdaten nicht verbessern. Es ist ein großer Aufwand die Realität genau bzw. möglichst nahe abzubilden, damit man sich davon im Training nicht zu sehr von dieser entfernt und so ganz im Gegenteil die Detektionsqualität abmildert. Im nächsten Schritt wird untersucht, inwiefern sich eine zweistufige Detektion auf die Erkennungsqualität in Bezug auf einen gemischten Datensatz auswirkt. Darüber hinaus stellt sich die Frage, zu welchen Teilen der Trainingsdatensatz aus synthetischen und „realen“ Daten zusammensetzen sollte.

### 4.4.3 Auswertung des zweistufigen gemischten Modells

Das nächste Modell besteht sowohl aus manuell gelabelten als auch aus synthetisch erzeugten Daten. Wie in **Tabelle 4.9** zu sehen, werden die 10.000 Bilddaten aus dem synthetischen Modell mit den 400 manuell gelabelten Bildern zu einem Datensatz vereint. Die Übrigen Trainingsparameter bleiben identisch wie in den vorherigen Modellen bestehen.

Tabelle 4.9: Übersicht der für das gemischte Training genutzten Parameter

Trainingsparameter	Werteintervall
Batch Size	17 Bilder
Bildgröße	800 px
Epochen	200
Anzahl der Trainingsbilder	10.400
GPU	<i>NVIDIA RTX 3090 Ti</i> (24 GB VRAM)
Anteil Validierungsdaten	10% der Trainingsbilder

Die Trainingsergebnisse des mit dem gemischten Datensatz angelegten Modells befinden sich genau zwischen den Trainingsergebnissen des synthetischen und manuellen Modells (siehe **Abbildung 4.36**). Die Validierungsdaten bestehen ebenfalls zu gleichen Anteilen aus synthetischen und manuellen Daten. Die Werte tendieren leicht mehr zu den guten Werten des synthetischen Modells. Präzision und Recall erreichen Werte von 0,8 bzw. über 0,9. Alle Verlustwerte der Validierung bis auf die Objektivität stagnieren bis zur letzten Epoche. Dieser Kurvenverlauf steigt ab der 100. Epoche wieder leicht an. Das Optimum liegt bei Epoche 120. Diese Werte weisen auf eine gute Detektionsqualität

innerhalb des Trainingsdatensatzes hin. Es gilt jedoch zu überprüfen, ob dies auch auf die Daten außerhalb dieser Datenmenge zutrifft.

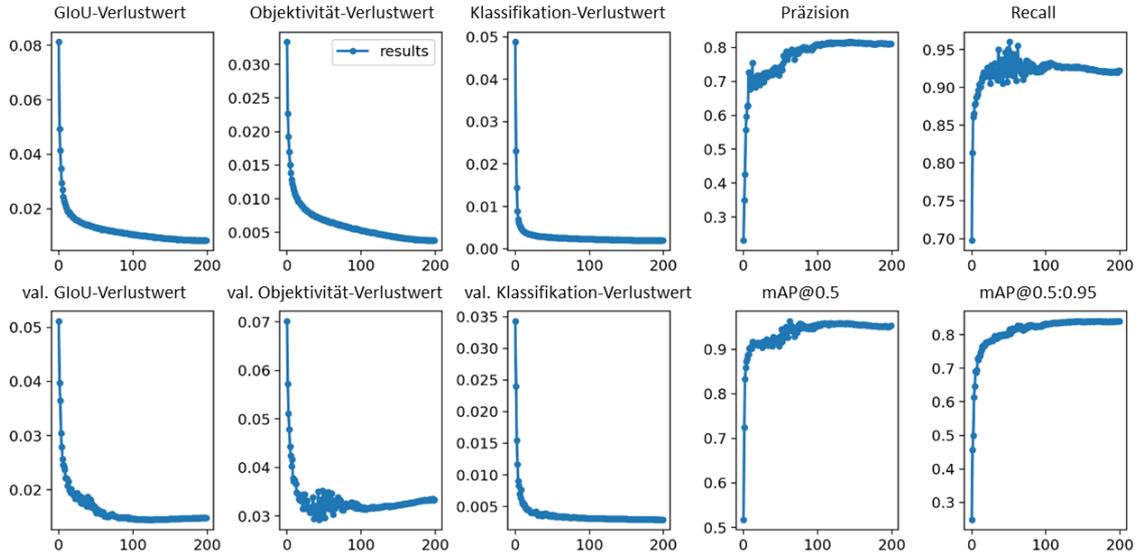


Abbildung 4.36: Trainingswerte zum gemischten Detektionsmodell

Beim Testen der Detektionsqualität wird ein Vertrauenswert von 0,25 und eine IoU-Schwelle von 0,2 gewählt. Die Gewichtung aus Epoche 120 des Trainings werden verwendet. Die Bildgröße in dem Input der Detektion wird auf 800 Pixel festgesetzt. Mit diesen Einstellungen werden 77,52% richtig positive Ergebnisse erzielt (siehe **Tabelle 4.10**). 6,2% der Detektionen sind falsch und 16,28% der Objekte werden durch den KI-Detektor nicht entdeckt. Damit ist dieses Detektionsmodell als besser einzustufen als das rein synthetische, allerdings schlechter als das rein manuell gelabelte Modell. In diesem Fall eignen sich reale Daten, welche manuell gelabelt werden, besser, um einen KI-Detektor zu trainieren als synthetische Daten.

Tabelle 4.10: Wahrheitsmatrix zum gemischten Modell

		Realität	
		Erkennung	Nein
Objekt- erkennung	Ja	77,52%	6,2%
	Nein	16,28%	-

Die grafische Auswertung der Klassen in Bezug auf das gemischte Modell ist in **Abbildung 4.37** zu finden. In diesem Modell werden die definierten Klassen bezüglich des RWDR nicht zuverlässig erkannt. Sowohl die Klasse des RWDR in realer Darstellung als auch in vereinfachter Darstellung erreichen globale Genauigkeiten von 0,5849 bzw. 0,40. Im Falle der vereinfachten Darstellung liegt dies an der hohen falsch-positiv-Rate. Einige der real dargestellten RWDR werden als vereinfachte Darstellung erkannt. Im Gegenzug

werden diese nicht als reale Darstellung erkannt, weshalb die falsch-negativ-Rate bei der Klasse der realen Darstellung ansteigt. Somit liegt die Verlustrate bei 0,2619 bzw. der Recall bei 0,7381. Genau den gleichen Wert wie der Recall erreicht die Präzision. Daher ist die Anzahl falsch positiver Detektionen genauso groß wie die Anzahl der falsch negativen Erkennungen.

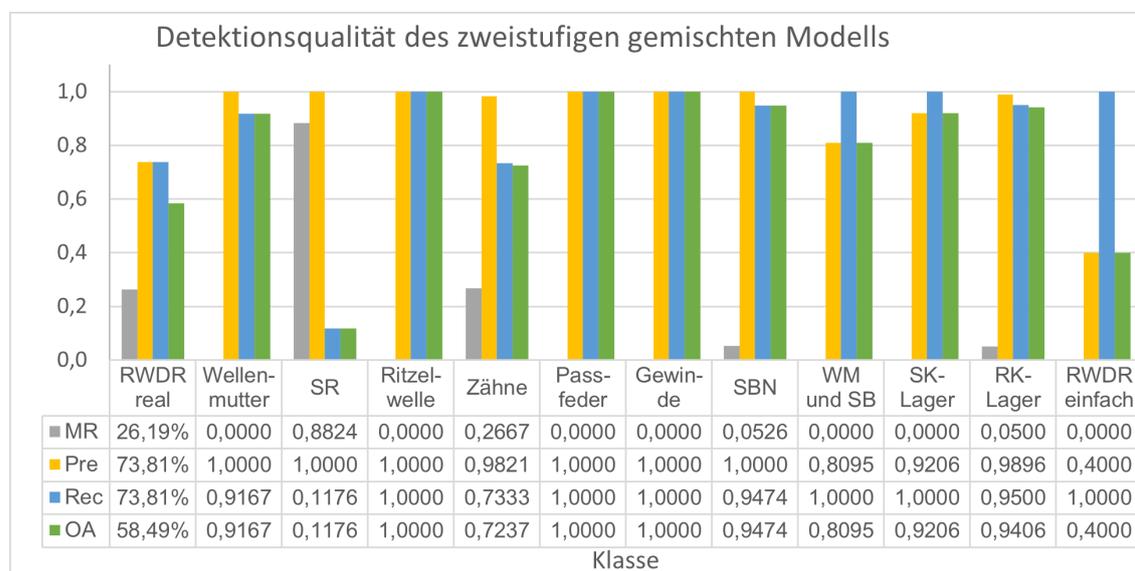


Abbildung 4.37: Klassenauswertung zum gemischten Modell

Der Sicherungsring ist diejenige Klasse, welche die schlechtesten Qualitätswerte aufweist. Es kommen zwar keine falsch positiven Ergebnisse vor, doch 88,24% der Sicherungsringe werden durch den KI-Detektor nicht erkannt. Dies führt zu einer globalen Genauigkeit von 0,1176. Die Detektion des Bauteils ist im Vergleich zum manuellen Modell deutlich herabgesetzt. Demgegenüber werden die Klassen Ritzelwelle, Passfeder und Gewinde zu 100% richtig erkannt. Die übrigen Werte bewegen sich auf einem Niveau von 0,70 bis 0,95 globaler Genauigkeit. Dies ist als zufriedenstellend zu bewerten.

Aus dem gemischten Modell lässt sich schlussfolgern, dass durch die Hinzunahme der synthetischen Daten das KI-Detektionsmodell verschlechtert wird. Der Trainingsdatensatz wird zwar vergrößert, ist jedoch nicht in der Lage, die Detektionsqualität zu verbessern. Reale Daten, welche manuell gelabelt werden, stellen sich als die am besten geeigneten Daten dar, um die Güte der Detektion am effektivsten zu verbessern. Es existiert eine Schwelle zur Hinzunahme von synthetischen Trainingsdaten, um ein KI-Detektionsmodell anzulernen, falls wenige Trainingsbilder vorliegen. Es wird vermutet, dass diese Schwelle bei unter 150 Trainingsbildern für diese Anwendung liegt. Es wird daher empfohlen, den Trainingsdatensatz zunächst mit anwendungsnahen Daten zu füllen. Dieser Schritt ist am effektivsten und stellt zunächst einen geringeren Arbeitsaufwand dar, weil das Nachbilden der Realität in den meisten Anwendungsfällen aufwendiger ist und dazu noch schlechtere Ergebnisse liefert. Aus diesen Gründen wird bei der weiteren

Optimierung des Detektionsmodells auf das manuelle Modell zurückgegriffen, welches mit realen Daten trainiert wird, wenngleich das gemischte Modell noch ein weiteres Mal bei der Analyse des Einflusses der Bildgröße verwendet wird.

## 4.5 Variation der Trainings- und Detektionsparameter

In dem folgenden Unterkapitel werden Trainings- und Detektionsparameter optimiert, um das Optimum der Detektionsqualität ausfindig zu machen. Außerdem kann mit dem Optimum die Einstufung der Fähigkeiten im nächsten Kapitel vorgenommen werden.

### 4.5.1 Gemischtes Modell mit Reduktion des synthetischen Bildanteils und erhöhter Bildgröße im Training

Zu den Optimierungen der Parameter werden ausschließlich die Testdetektionen ausgewertet. Zunächst wird das gemischte Modell mit einer Bildgröße von 1200 Pixel trainiert. Dies soll zeigen, ob sich eine höhere Bildgröße im Training positiv auf die Trainingsergebnisse auswirkt. Die Erhöhung der Bildgröße in Pixel bei gleichen Abmessungen der Gesamtzeichnung bringt eine größere Auflösung mit sich. Außerdem wird die Anzahl der synthetisch generierten Bilder verringert und beträgt 5000. Damit werden in diesem Modell 5400 Trainingsbilder für das Anlernen verwendet.

Detektiert wird trotz dessen mit einer Bildgröße von 800 Pixel. Die Detektionsparameter werden auf dem oben genannten Standard konstant gehalten. Dies führt zu den in **Tabelle 4.11** dargestellten Ergebnissen. Die richtig positiven Detektionen nehmen durch die Änderung der Bildgröße im Training von etwa 77% auf 88,13% zu. Die falsch positiven Ergebnisse nehmen ebenfalls zu und machen einen Anteil von 10,83% aus.

Tabelle 4.11: Wahrheitsmatrix zum gemischten Modell 1200

	Realität		
	Erkennung	Nein	
Objekt- erkennung	Ja	<b>88,13%</b>	<b>10,83%</b>
	Nein	<b>1,04%</b>	<b>-</b>

Demgegenüber sinkt der Anteil falsch negativer Detektionen auf etwa 1%. Die Tatsache, dass die Detektionsqualität des Modells bei höherer Bildgröße steigt, deutet darauf hin, dass die Qualität von einer höheren Bildgröße profitiert. Bei der Betrachtung von Abbildung 4.32 ist zu erkennen, dass die synthetisch erstellte Welle mit aufgesetzten Bauteilen kleiner aufgelöst ist als die realen Trainingsbilder. Dies ist der Tatsache geschuldet, dass im Algorithmus des automatischen Wellengenerators eine randomisierte

Positionierung vorgesehen wird. Damit ein wenig Spielraum dafür vorhanden ist, füllen die erzeugten Wellen die Größe des Bildes niemals ganz aus. Es wird festgehalten, dass der automatische Wellengenerator in dieser Hinsicht optimiert werden kann.

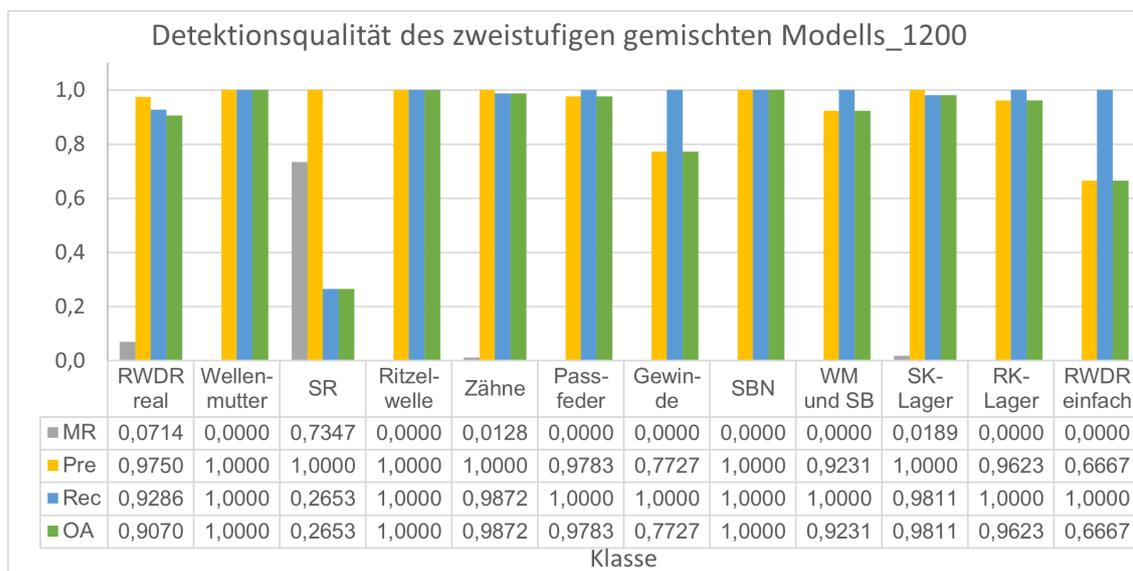


Abbildung 4.38: Klassenauswertung zum gemischten Modell\_1200\_800

Bei dieser Detektion fällt vor allem auf, dass einige Klassen besser erkannt werden als im manuellen Modell (siehe **Abbildung 4.38**). Die Klasse RWDR\_real erreicht eine globale Genauigkeit von 0,907 im Vergleich zu 0,881. Hier treten im Gegensatz zu dem manuell trainierten Modell falsch positive Detektionen auf. Dies kann darauf hinweisen, dass die Detektionsparameter bzgl. des manuellen Modells noch nicht ihr Optimum erreicht haben. Die Klasse Schrägkugellager wird ebenfalls marginal besser erkannt (0,9811 vs. 0,9608). Die Klassen profitieren von einer erhöhten Bildgröße und höheren Bildauflösung im Training. Des Weiteren beträgt die globale Genauigkeit der Klasse Sicherungsring 0,2653. Dieser Wert resultiert aus vielen falsch negativen Ereignissen. Viele der Sicherungsringe werden nicht durch den Detektor erkannt. Diese Klasse kann durch einen individuellen Vertrauenswert profitieren, indem dieser Schwellenwert individuell angepasst wird. Dies kann ebenfalls für andere Klassen zweckdienlich sein. Hier besteht ein Potential der Optimierung der Detektionsqualität.

#### 4.5.2 Manuelles Modell mit erhöhter Bildgröße in der Detektion

Als nächstes wird der Einfluss der Bildgröße im Detektionsschritt getestet. Hierfür wird das manuelle Trainingsmodell herangezogen und während der Detektion eine Bildgröße von 1200 Pixel als Input verwendet. Die übrigen Detektionsparameter werden auf dem Standard konstant gehalten. Dabei ergeben sich die folgenden in **Tabelle 4.12** abgebildeten Ergebnisse. Die richtig positiven Ergebnisse nehmen ab und machen einen Anteil

von 85,86% aus. Aufgrund der höher aufgelösten Bilder und den größer dargestellten Bauteilen nehmen die falsch positiven und falsch negativen Detektionsergebnisse zu. Die Zunahme dieser Ergebnisse spricht dafür, dass das Anlernen nur für bestimmte Szenarien geeignet ist.

Tabelle 4.12: Wahrheitsmatrix zum manuellen Modell 800\_1200

Objekt- erkennung	Realität		
	Erkennung	Ja	Nein
	Ja	85,86%	4,99%
Nein	9,15%	-	

Innerhalb bestimmter Grenzen der Bildgröße und Bildauflösung sind eindeutige Unterschiede in der Detektionsqualität vorhanden. Wenn allerdings verschiedene Bildgrößen und Bildauflösungen trainiert werden, wirkt sich dies negativ auf die Detektionsgüte aus. Bei einer Variation, der eben genannten Einflüsse würde, das Modell bei stark unterschiedlich aufgelösten Bildern und Bildgrößen bessere Leistungen erzielen. Wenn das Optimum der Detektionsqualität insgesamt erreicht werden soll, dann sollte sich sowohl das Anlernen als auch die Detektion in bestimmten Grenzen der Bildauflösung und Bildgröße befinden. Die Bildgröße, die in der Detektion verwendet wird, sollte kleiner oder gleich der im Training verwendeten Bildgröße sein.

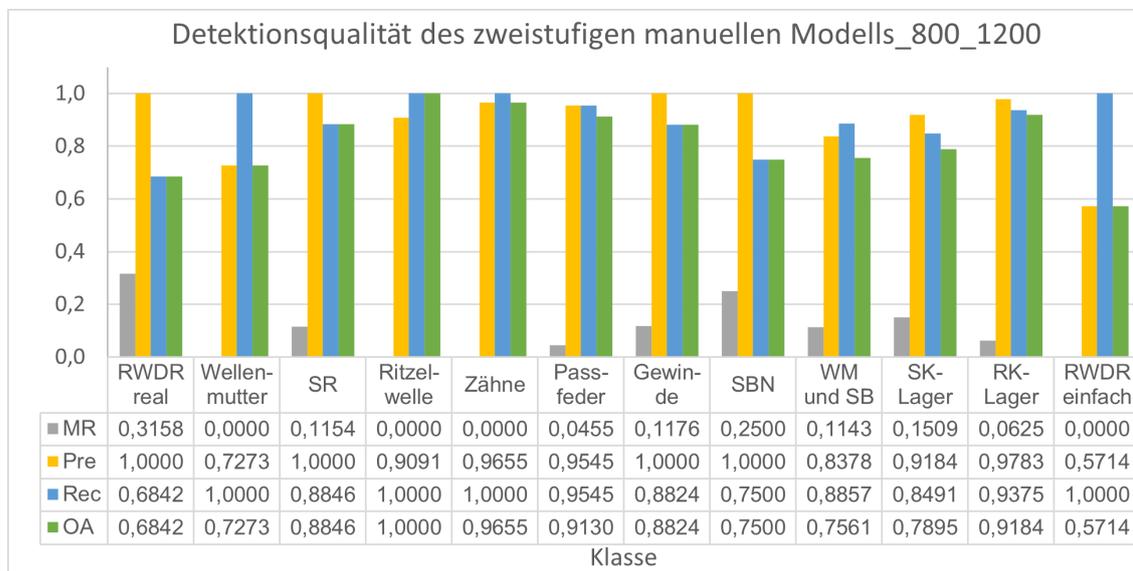


Abbildung 4.39: Klassenauswertung zum manuellen Modell\_800\_1200

Wenn eine Detektion mit höherer Bildgröße von 1200 Pixel durchgeführt wird, wird die reale Darstellung des RWDRs durch den Detektor schlechter erkannt, als wenn mit einer Detektion von 800 Pixel gearbeitet wird (siehe **Abbildung 4.39**). Die Detektionsqualität fast aller Klassen wird gehemmt. Demgegenüber profitiert die Klasse Sicherungsring von

der höheren Bildgröße, sodass der Wert der globalen Genauigkeit von 0,7818 auf 0,8848 ansteigt. Dies kann ein Ansatz für einen zweistufigen Detektor sein, indem verschiedene Vergrößerungswerte für die Festlegung von ROI definiert werden, sodass klassenabhängig Bereiche fokussiert werden, um die Detektionsqualität global zu optimieren.

### 4.5.3 Manuelles Modell mit erhöhter Bildgröße im Training

Dieser Abschnitt analysiert den Einfluss der Bildgröße im Training. Es wird mit einer Bildgröße von 1200 Pixel angelernt. Anschließend findet eine Detektion sowohl mit einer Bildgröße von 800 Pixel als auch mit 1200 Pixel statt. Die Erhöhung der Bildgröße führt dazu, dass die Batch Size von 17 auf 7 Bilddaten pro Iteration sinkt. In **Tabelle 4.13** ist die Wahrheitsmatrix für die Ergebnisse der Detektion mit einer Bildgröße von 800 Pixel dargestellt. Die Ergebnisse sind ähnlich zum manuellen Modell, welches mit einer Bildgröße von 800 Pixel trainiert und detektiert wird. Allerdings nehmen die falsch positiven Ergebnisse zu und die falsch negativen Ergebnisse ab.

Tabelle 4.13: Wahrheitsmatrix zum manuellen Modell 1200\_800

	Realität		
	Erkennung	Ja	Nein
Objekt- erkennung	Ja	94,22%	2,78%
	Nein	3,00%	-

Insgesamt beträgt die durchschnittliche globale Genauigkeit 94,22% und liegt damit etwa ein Prozent unter der des manuellen Modells, welches mit 800 Pixel angelernt wird. Dies liegt wie bereits erwähnt an der Zunahme der falsch positiven Detektionen, weshalb die Präzision darunter sinkt. Dies liegt vor allem daran, dass die Klasse Rillenkugellager schlechtere Präzisionswerte erzielt (0,90 vs. 1, siehe **Abbildung 4.40**). Die vergrößerte Borde am Innen- bzw. Außenring des Schrägkugellagers im Vergleich zum Rillenkugellager wird nicht erkannt, wenn diese nicht so stark ausgeprägt ist. Dadurch kommt es zu falsch positiven Detektionen, weil der Detektor dem Objekt die Klasse Rillenkugellager zuweist, obwohl es sich um ein Schrägkugellager handelt. Teilweise sind diese Unterschiede mit dem menschlichen Auge nur schwer erkennbar.

Andere Klassen wie die reale Darstellung des RWDR und der Sicherungsring übertreffen die globalen Genauigkeitswerte. Wenn die Lagerklassen aus der Detektion ausgeschlossen werden, liegt die durchschnittliche globale Genauigkeit über der des manuellen Standardmodells, welches momentan das Optimum darstellt. Die Tendenz des zuvor analysierten gemischten Modells, welches ebenfalls mit einer Bildgröße von 1200 Pixel angelernt wird, kann anhand der in diesem Abschnitt durchgeführten Auswertung

bestätigt werden. Einige Klassen, wie der RWDR und der Sicherungsring, können von höheren Bildgrößen im Training profitieren. Es kann durchaus getestet werden, ob sich ein gemischtes Training mit verschiedenen Bildauflösungen und Bildgrößen anbietet, wenn merkmalarmer Objekte erkannt werden sollen. Das genannte Potential besteht, allerdings wird es innerhalb dieser Arbeit nicht weiter getestet, denn die Machbarkeit der Detektionen in TZ wurde hiermit bewiesen. Es lassen sich kleine und detailarme Objekte durch einen zweistufigen Detektor erkennen. Bisher müssen keine Einschränkungen in Bezug auf nicht erkennbare Objekte getätigt werden.

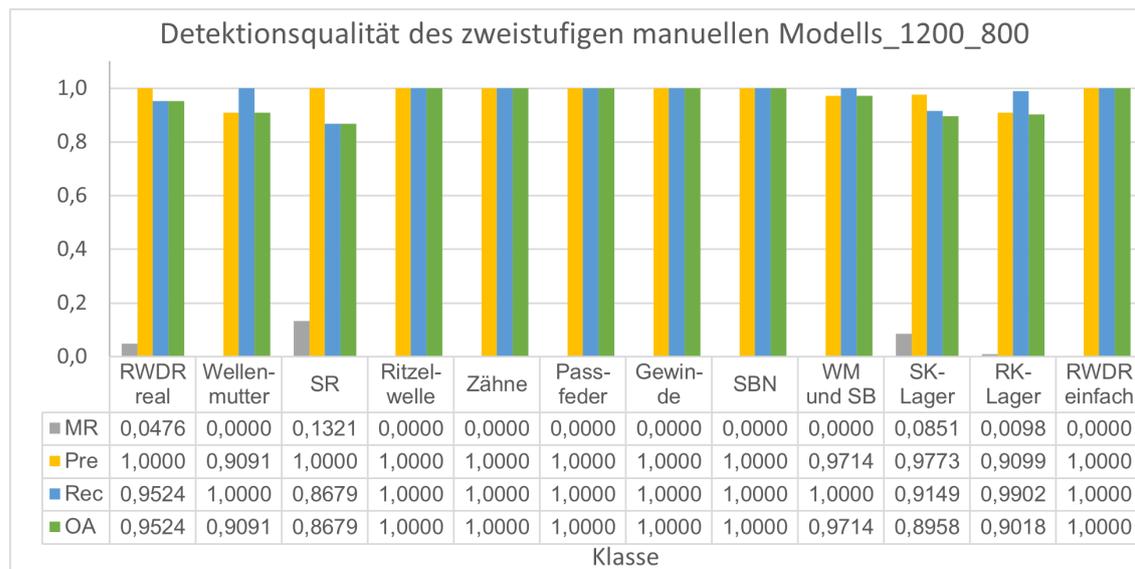


Abbildung 4.40: Klassenauswertung zum manuellen Modell\_1200\_800

Die Detektionsqualität erreicht mindestens die Grenze der ausreichenden Erkennungsqualität, welche in dieser Arbeit auf eine globale Genauigkeit von 0,8 gesetzt wird. Damit sieht der Autor die grundsätzliche Erkennbarkeit als gegeben an, die durch weitere Optimierungen und ein angepasstes Training weiter gesteigert werden kann. Vielmehr werden in dieser Arbeit die verfügbaren Stellschrauben identifiziert und die effektivsten analysiert und optimiert. Das Training mit höheren Bildgrößen kann sich negativ auf die Detektionsqualität einiger Klassen auswirken. Dies scheint vor allem merkmalarmer Klassen zu betreffen. Wenn falsch positive Detektionen ansteigen, nehmen die falsch negativen Detektionen in der Regel auch zu, weil das falsch erkannte Objekt letztendlich nicht mehr markiert wird, da der non-max suppression Algorithmus einen Filter bei übereinanderliegenden Erkennungen anwendet. Dieser filtert alle Markierungen bis auf die am wahrscheinlichsten zutreffende in einer gewissen Umgebung ab einem bestimmten Überschneidungsgrad heraus. Es kann dennoch vorkommen, dass eine falsch positive Detektion über einer korrekt markierten BB liegt.

Die Hypothese, dass sich die Detektionsqualität am besten verhält, wenn die Bildgrößen im Training- und nachfolgendem Detektionsschritt gleich sind, bewahrheitet sich nicht.

Bei der Betrachtung von **Tabelle 4.14** sind kaum Unterschiede im Vergleich zur Tabelle 4.13 zu erkennen. Die Detektionsqualität hat sich wenig verändert.

Tabelle 4.14: Wahrheitsmatrix zum manuellen Modell 1200\_1200

Objekt- erkennung	Realität		
	Erkennung	Ja	Nein
	Ja	94,4%	2,8%
Nein	2,8%	-	

Die durchschnittliche globale Genauigkeit von 0,9440 hat sich ebenfalls nicht groß verändert. Jedoch haben sich die Parameterwerte einiger Klassen verändert (siehe **Abbildung 4.41**). Falsch positive Detektionen nehmen in Bezug auf die Klassen RWDR\_real, Wellenmutter, Sicherungsblechnut, Schrägkugellager ab, weshalb die Präzision bei diesen Klassen ansteigt. Diese Detektionsergebnisse nehmen bei den Rillenkugellagern zu, weshalb der Präzisionswert der Klasse Rillenkugellager abnimmt. Die Zunahmen und Abnahmen heben sich im Durchschnitt auf, sodass die oben beschriebenen Werte der Tabelle 4.13 gleichgeblieben sind. Die beschriebene Situation wirkt sich analog auf die globalen Genauigkeitswerte der Klassen aus. Die zuvor genannten Auswirkungen der im Training genutzten Bildgröße bezüglich der Klasse RWDR und der Lager wird durch diese Analyse gestützt. Je nachdem in welcher Auflösung und Bildgröße eine TZ nachher vorliegt, kann die Vorschaltung einer Logik zur Auswahl eines passenden Modells, welche mit verschiedenen Bildgrößen für den jeweiligen Anwendungsfall trainiert werden, positiv für die Anwendung sein.

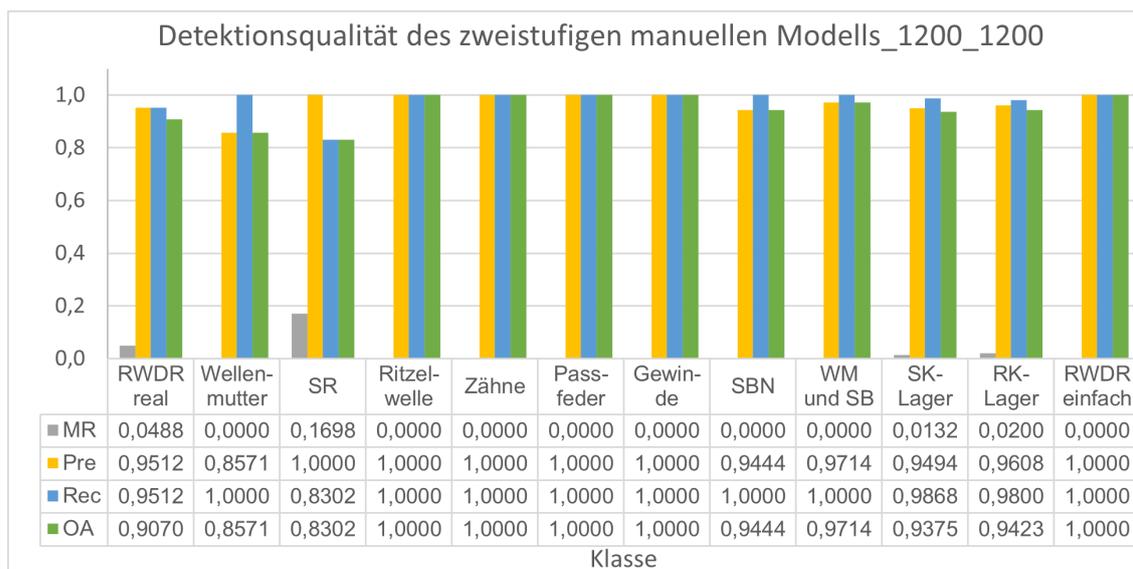


Abbildung 4.41: Klassenauswertung zum manuellen Modell 1200\_1200

#### 4.5.4 Manuelles Modell mit Variation der Detektionswerte

##### Vertrauenswert und IoU-Schwelle

In diesem Abschnitt wird analysiert, welchen Einfluss die Detektionsparameter Vertrauenswert und IoU-Schwellenwert einnehmen. Der Vertrauenswert wird in einem Intervall von 0,3 bis 0,6 in Zehntel-Schritten variiert. Danach wird der IoU-Schwellenwert von 0,2 auf 0,5 verändert. Das Ergebnis stellt heraus, welchen Einfluss die Parameter auf die Detektionsgüte der Klassen haben. Trainiert und detektiert wird jeweils mit 800 Pixel (Standardmodell).

Zunächst wird **Abbildung 4.42** betrachtet. In der Detektion wird der Vertrauenswert auf 0,3 eingestellt. Im Vergleich zum Standard nimmt die globale Genauigkeit der Klassen Wellenmutter und Wellenmutter mit Sicherungsblech ab. Dies liegt daran, dass der Detektor diese Klassen bei niedrigeren Vertrauenswerten nicht zuverlässig unterscheiden kann. Der Unterschied, welcher in der Anwesenheit des Sicherungsbleches liegt, kann nicht differenziert werden. Alle anderen Genauigkeitswerte der Klassen nehmen ebenfalls ab oder bleiben unverändert. Einzig die Klasse RWDR\_real erreicht bessere Werte (0,9524 im Vergleich zu 0,881). Diese Klasse ist ein gutes Beispiel dafür, wie eine Parameteroptimierung bezüglich einer Klasse aussehen kann. Der Vertrauenswert wird solange abgesenkt, bis die Präzision nicht mehr die 100% Marke erreicht. Bis dahin nehmen die falsch negativen Ergebnisse ab und der Recall nimmt zu. Wenn die erste falsch positive Detektion erreicht wurde, wird der zuletzt verwendete Vertrauenswert herangezogen. Insgesamt wird eine durchschnittliche globale Genauigkeit von 0,9383 erreicht.

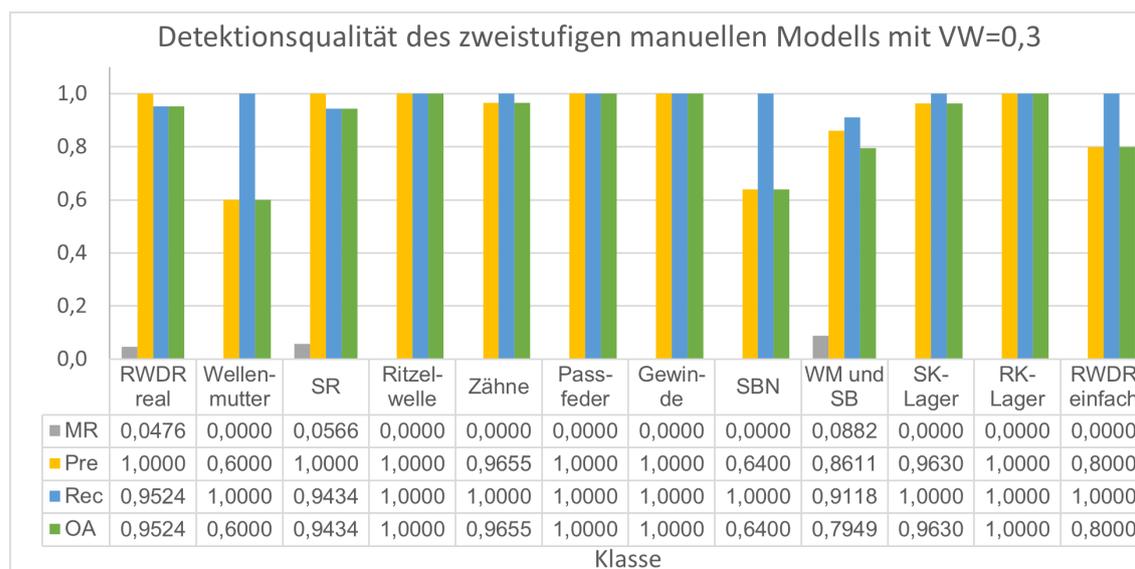


Abbildung 4.42: Klassenauswertung zum Standardmodell mit Vertrauenswert 0,3

Als nächstes wird der Vertrauenswert auf den Wert 0,5 festgesetzt. Grundsätzlich sollten dadurch die falsch positiven Detektionen abnehmen und die falsch negativen Ergebnisse

zunehmen, weil dadurch eine Markierung erst dann vorgenommen wird, wenn die Sicherheit über diesem Wert liegt. Die globale Genauigkeit beträgt im Mittel 0,943 und liegt damit knapp unter der Detektionsgüte mit einem Vertrauenswert von 0,4. Bei der Betrachtung von **Abbildung 4.43** ist auffällig, dass die globale Genauigkeit vieler Klassen den Maximalwert von 1 erreicht. Allerdings werden die Klassen RWDR\_real und Sicherungsring seltener erkannt. Dies ist daran zu erkennen, dass die Verlustrate zunimmt. Im Vergleich zur Detektion mit einem Vertrauenswert von 0,3 nehmen die Recall Werte insgesamt ab und die Präzisionswerte zu.

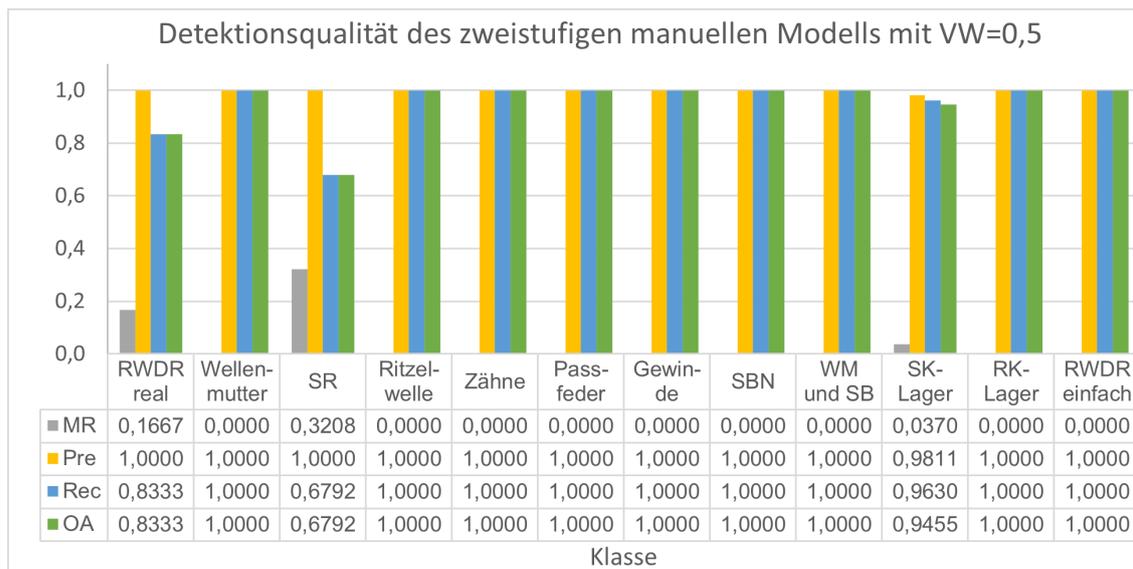


Abbildung 4.43: Klassenauswertung zum Standardmodell mit Vertrauenswert 0,5

Die durchschnittliche globale Genauigkeit der letzten beiden Detektionsversuche erreichen ähnliche Werte, weil sich die Abnahme der falsch positiven Detektionen mit der Zunahme der falsch negativen Detektion gegenseitig aufheben. Das heißt aber nicht, dass das Optimum für den Vertrauenswert für die meisten Klassen bei 0,4 liegt, sondern vielmehr, dass der Durchschnitt der optimalen Vertrauenswerte im Intervall von, 0,3 bis 0,5 die höchsten globalen Genauigkeitswerte annimmt. Es lässt darauf schließen, dass sich die Optima der Vertrauenswerte für die meisten Klassen in diesem Intervall befindet. Es ist durchaus möglich, dass das Optimum des Vertrauenswertes für den Sicherungsring bei unter 0,3 liegt.

Umgekehrt kann das Optimum des Vertrauenswert bezüglich der Lagerklassen bei über 0,5 liegen. Diese Optima sollen durch die weitere Analyse ermittelt werden, sodass Empfehlungen für die Einstellungen der Detektion zur Steigerung der Detektionsgüte vorhergesagt werden können. Außerdem kann im Fazit darauf eingegangen werden, wie sich die Vertrauenswerte in Abhängigkeit von den Eigenschaften bzw. der Merkmaldichte verhalten, damit eine optimale Erkennung von Bauteilen in TZ erreicht werden kann.

In der **Abbildung 4.44** ist der Diagramm zur Auswertung der Detektion mit Vertrauenswert von 0,6 zu sehen. Anhand dieses höher angesetzten Wertes ist zu erkennen, welche Klassen sich gut für die KI-Detektion eignen. Wellenmutter, Ritzelwelle, Zähne, Passfeder(nut), Gewindeabsatz, Sicherungsblechnut, Wellenmutter und Sicherungsblech sowie die vereinfachte Darstellung des RWDR erreichen globale Genauigkeiten von eins und werden somit zuverlässig erkannt. Die Erkennung der anderen Klassen ist ebenfalls möglich, allerdings mit geringerer Sicherheit. Wenn eine niedrigere Sicherheit gewählt werden muss, um eine gewisse Detektionsgüte zu erlangen, können Probleme bei hohen Anforderungen resultieren. Bei komplexen Baugruppenzeichnungen mit wesentlich mehr Bauteilen und Merkmalen steigt die Wahrscheinlichkeit falsch positiver und falsch negativer Detektionsergebnisse, da ein größerer Fehlerspielraum vorhanden ist. Bei den Klassen, bei denen die Präzision eins beträgt und der Recall gleichzeitig weniger als 1 beträgt, profitieren von niedrigeren Vertrauenswerten.

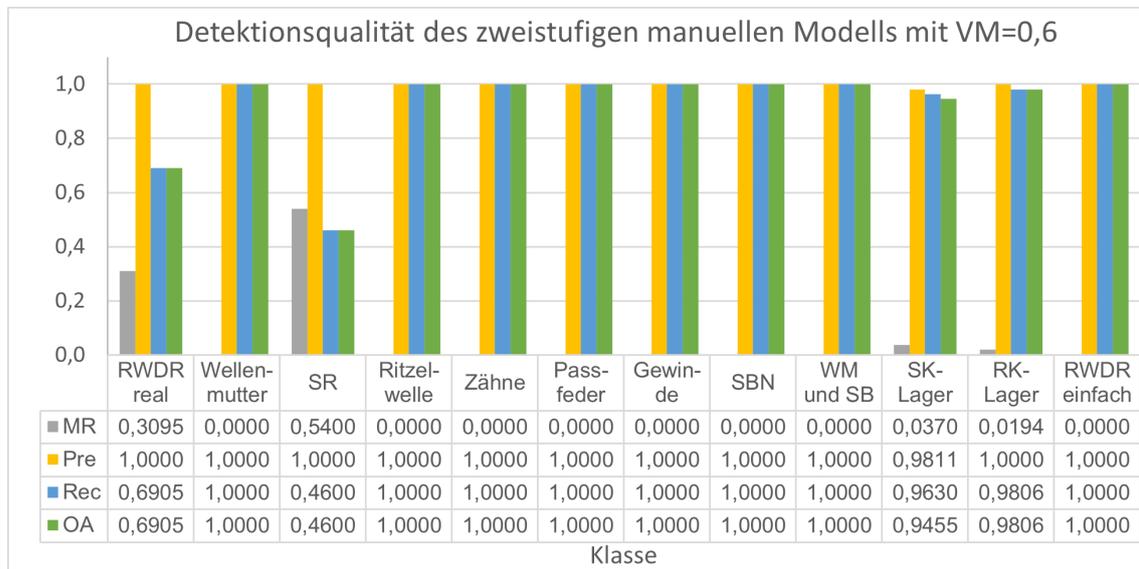


Abbildung 4.44: Klassenauswertung zum Standardmodell mit Vertrauenswert 0,6

Gerade bei den Klassen RWDR\_real und Sicherungsring nimmt die Verlustrate zu, weil diese Objekte nicht erkannt werden. Die Wahrscheinlichkeit, dass eine Markierung ausgeführt wird, also die Klasse im Bild vorhergesagt wird, unterschreitet den Vertrauenswert. Daher folgen falsch negative Ergebnisse. Bei einem Vertrauenswert von 0,6 in der Detektion werden rund 50% der Sicherungsringe erkannt. Falsch positive Detektionen kommen in Bezug auf dieses Bauteil nicht vor. Zu Anfang wurde der Standardwert von 0,2 als IoU-Schwelle festgelegt, da sich dieser in früheren Modellen als Optimum herausgestellt hat. In den *YOLO*-Anwendungen aus der zur Verfügung stehenden Literatur wird der Standardwert der IoU-Schwelle auf 0,5 festgelegt. Dieser Wert hat insgesamt einen sehr geringen Einfluss auf die Detektionsqualität, weil die GIoU-Verlustwerte sehr gering sind. Dennoch soll hier das Optimum ermittelt werden,

damit eine detaillierte Empfehlung zu allen Einstellungen sowohl im Training als auch in der Detektion ausgesprochen werden kann. Dazu wird im Folgenden die **Abbildung 4.45** betrachtet. Dies stellt das Diagramm zur Auswertung der IoU-Schwelle von 0,5 bereit. Der Vertrauenswert wird auf 0,4 festgesetzt. Es ergeben sich marginale Unterschiede zu Abbildung 4.31. Die durchschnittliche globale Genauigkeit steigt von 0,955 auf 0,9601. Damit beträgt das Optimum des IoU-Schwellenwerts 0,5. Da die Unterschiede solch kleine Ausmaße annehmen, wird dieser Wert nicht weiter untersucht bzw. optimiert.

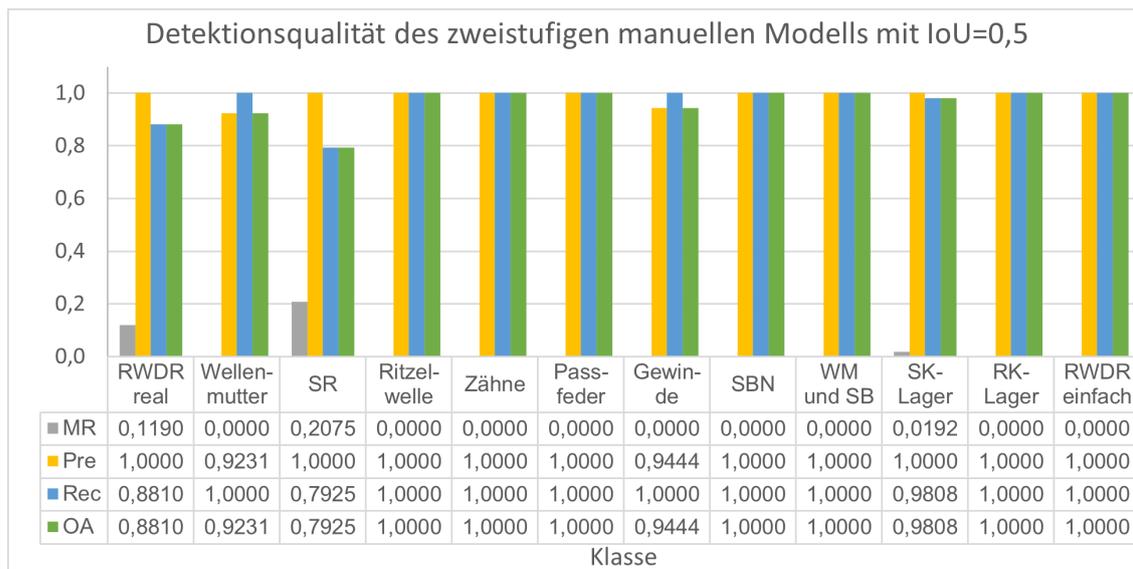


Abbildung 4.45: Klassenauswertung zum Standardmodell mit Vertrauenswert 0,4 und IoU-Schwelle von 0,5

Der Vertrauenswert der Detektion ist ein Wert, der eine Detektion abhängig von der Wahrscheinlichkeit des Vorkommens setzt. Die Analyse hat gezeigt, dass sich dieser Wert klassenindividuell optimieren lässt. Es ist daher nicht möglich einen globalen Vertrauenswert zu wählen, bei dem alle Klassen das Optimum ihrer jeweiligen Detektionsqualität erreichen. Deshalb wird darauf verwiesen, dass eine lokale Optimierung der Vertrauenswerte für die jeweilige Klasse ratsam ist. Mit dieser Analyse der Variation der Vertrauenswerte ist es am Ende dieses Unterkapitels im Fazit möglich, ein Intervall für den Vertrauenswert einer jeden Klasse anzugeben.

Trotz des nicht an die Klassen angepassten Vertrauenswertes im Detektionsschritt konnte eine durchschnittliche globale Genauigkeit von 0,96 erreicht werden. Dies bedeutet, dass die meisten definierten Klassen zuverlässig mit Hilfe der KI-Detektion erkannt werden können. Die meisten Klassen erreichen das Optimum der globalen Genauigkeit von eins. Es existiert eine Klasse, welche nicht immer zuverlässig detektiert werden kann. Dies ist die Klasse Sicherungsring, welche mit dem durchschnittlichen Optimum

des Vertrauenswertes oftmals nicht erkannt wird. Dies hemmt insgesamt den Wert der durchschnittlichen globalen Genauigkeit.

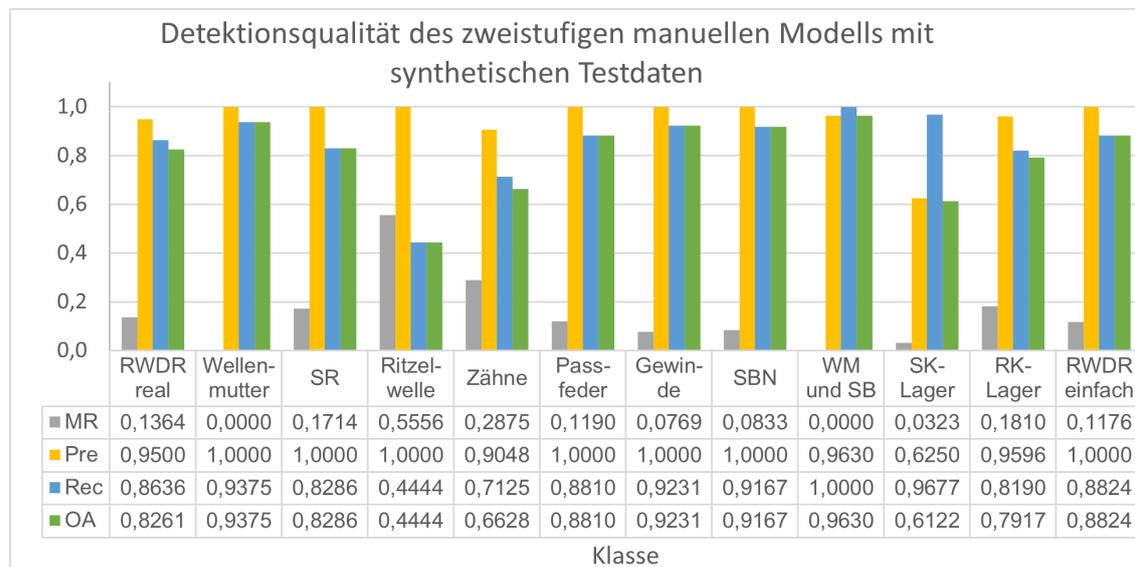


Abbildung 4.46: Klassenauswertung zum manuellen Modell getestet mit synthetischen Daten in der Detektion

Zuletzt wird eine Analyse durchgeführt, um zu zeigen, warum die synthetisch erstellten Zeichnungen wesentlich schlechter für das Anlernen der KI geeignet sind als die realen Daten. Dafür werden Detektionen durch das manuelle Standardmodell an synthetischen Zeichnungen durchgeführt. Die Auswertung dieser Daten ist in **Abbildung 4.46** dargestellt. Für den Betrachter sticht ins Auge, dass diese Detektionsergebnisse nicht zu den vorher ausgewerteten Trainingsergebnissen passen. Aufgrund der geringeren Größe der Welle im Gesamtbild, ergeben sich Schwierigkeiten, die Lagerklassen voneinander zu unterscheiden (siehe **Abbildung 4.47**).

Auf der anderen Seite schwanken die meisten globalen Genauigkeitswerte der Klassen um die Marke von 0,8. Wenn die Klasse Schrägkugellager aus der Analyse ausgeklammert wird, befinden sich die Präzisionswerte nahe dem Maximum. Das bedeutet, dass wenige falsch positive Detektionen ausgeführt werden. Die Abnahme der durchschnittlichen globalen Genauigkeit auf 0,7795 ist auf die falsch negativen Ergebnisse zurückzuführen. Im Bild enthaltene Objekte werden nicht erkannt. Dies wird durch die Recall-Werte bestätigt, welche im Durchschnitt 0,8353 betragen.

Der tatsächliche Grund für die Abmilderung der Qualitätsparameter fällt bei der Betrachtung der **Abbildung 4.47** auf. Hier ist zu erkennen, dass die Störlinien im Bereich der Welle einen Einfluss auf die Detektionen nehmen. Die schraffierten Rechtecke überdecken Objekte und sorgen dafür, dass die Erkennung gehemmt wird. In **Abbildung 4.47** trifft dies auf die Klassen Schrägkugellager, Sicherungsring, RWDR\_real und Passfeder zu. Die Störlinien überdecken die Objekte, sodass diese nicht durch den Detektor markiert

werden. Die sich in den anderen Bildbereichen außerhalb der Störlinien befindlichen Objekte werden alle ausnahmslos richtig positiv erkannt. Daraus lässt sich schlussfolgern, dass die Störlinien einen negativen Einfluss auf die Detektionsqualität nehmen und nicht wie erhofft die Robustheit insofern steigern, dass die Detektionsgüte verbessert wird.

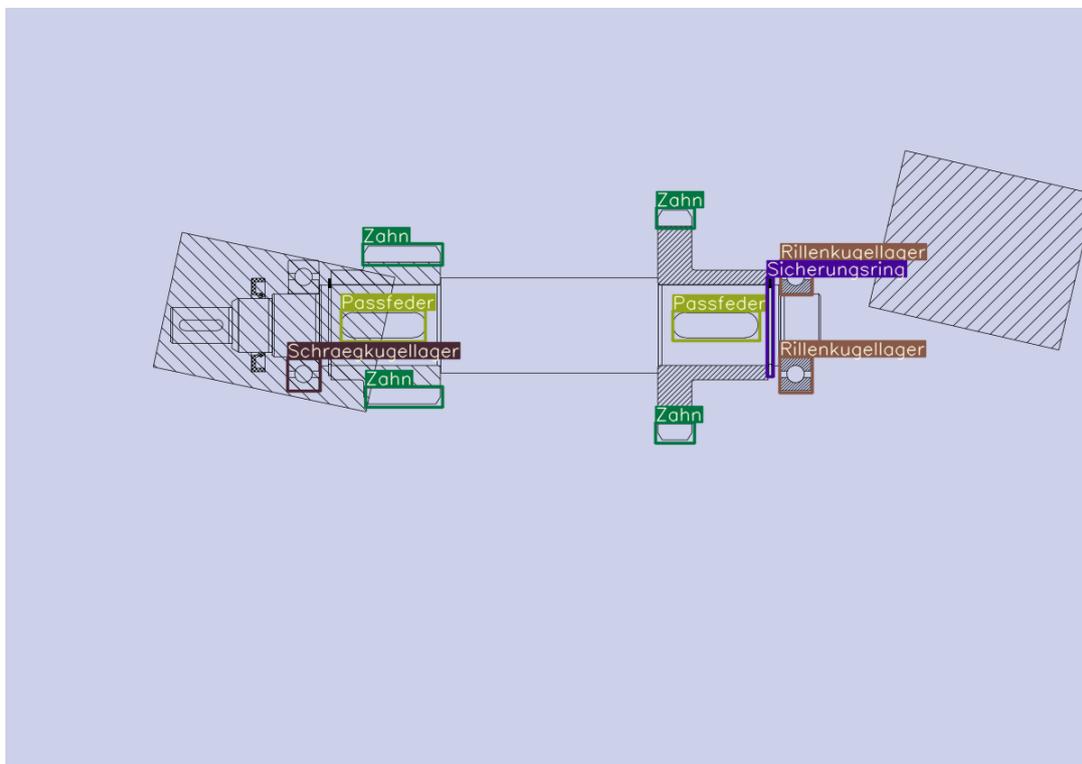


Abbildung 4.47: Detektion von synthetisch erstellten Bildern mit dem manuellen Modell

Das oben beschriebene und durchgeführte Vorgehen kann genutzt werden, um synthetische Daten zu verifizieren und validieren. Die Anpassung der Störlinienfunktion (entfernen oder verbessern), wird hier als eine Verbesserungsoption zum automatischen Wellengenerator genannt. Das Einfügen der Störlinien sollte im Optimierungsfall der Realität angenähert werden. Dazu können z. B. Bemaßungen und Hilfslinien von Positionsnummern hinzugefügt werden. Allerdings sollte darauf geachtet werden, dass die Objekte nicht zu sehr überdeckt werden. Eine weitere Optimierung des automatischen Wellengenerators ist die Anpassung der tatsächlichen Größe der Welle innerhalb des Bildes. Die Bildgröße und Auflösung sollte durch den Nutzer vor der Erstellung der synthetischen Daten in einer graphischen Benutzeroberfläche einstellbar sein. Wie in Abbildung 4.47 zu sehen, füllt die erstellte Welle nicht das ganze Bild aus und wirkt wesentlich kleiner als die Wellen, welche zuvor analysiert werden. Die Wellen werden in diesem Entwicklungsstadium mit einem großen Offset ausgeschnitten. Mit der Weiterentwicklung des zweistufigen Detektors konnten genauere Detektionen erreicht werden, weshalb eine Welle relativ genau und präzise ausgeschnitten werden kann.

Der Einfluss der farblichen Veränderung innerhalb der Bilder, welche in den automatischen Wellengenerator implementiert wird, wird nicht getestet. Bisher wurden zwar Scans und Fotos für die Auswertung der Detektionsergebnisse verwendet, allerdings wurde darauf geachtet, dass diese qualitativ hochwertig sind. Scans werden mit einer Auflösung von 300 dpi und Bilder mit einer Bildgröße von mindestens 3840x2160 (4K) aufgenommen durch eine Kamera angefertigt. Dies entspricht dem heutigen Standard, wenngleich schlechtere Bildgrößen und Auflösungen möglich sind, wenn der Benutzer für die Bilderfassung verantwortlich ist.

Als Addendum wird das synthetische Modell erneut getestet, um den Einfluss der Störgrößen zu beziffern. Darüber hinaus soll das tatsächliche Potential der synthetisch hergestellten Daten dadurch ermittelt werden. In **Abbildung 4.48** ist ein Diagramm dargestellt, welches die Qualitätswerte bezüglich der Parameter aufzeigt. Die Validierung der Werte wird mit realen Bilddaten ermittelt. Weiterhin kann der Sicherungsring nicht erkannt werden, da dieser eine globale Genauigkeit von 0 aufweist. Die Präzision zur Klasse des Sicherungsrings wird auf null gesetzt, obwohl der Wert nicht ermittelt werden kann, weil die Division durch null nicht erlaubt ist. Die übrigen globalen Genauigkeiten betragen für alle Klassen mindestens 0,8. Damit steigt die durchschnittliche globale Genauigkeit von 0,3055 (siehe Abschnitt 4.4.2) auf 0,7975. Damit erreicht das synthetische Modell nicht gänzlich die Qualitätswerte des manuellen Modells. Jedoch sollte das gemischte Modell mit diesen Daten ebenfalls Werte der durchschnittlichen globalen Genauigkeit von über 0,9 im Mittel erreichen.

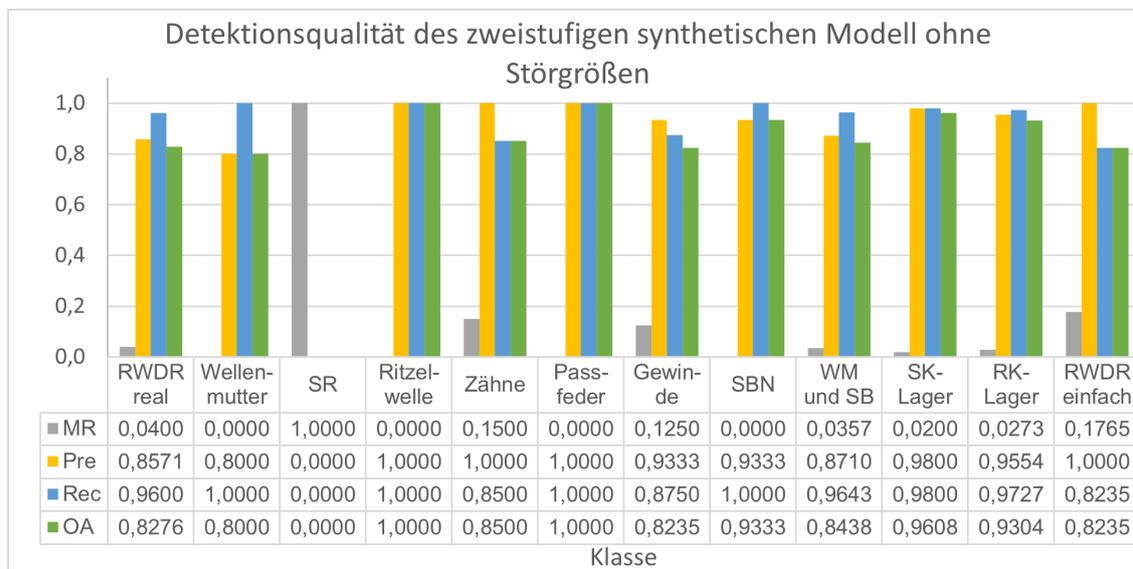


Abbildung 4.48: Klassenauswertung zum synthetischen Modell ohne Störgrößen

Schlussendlich erreicht das synthetische Modell ausreichende Genauigkeitswerte, um eine zuverlässige Detektion von Bauteilen innerhalb einer TZ durchführen zu können. Trotz dessen lassen sich die Qualitätswerte auf einem niedrigeren Niveau als im manuel-

len Modell lokalisieren. Damit wird weiterhin empfohlen, die KI-Detektion zunächst mit realen Bilddaten anzulernen. Nur wenn eine sehr geringe Anzahl an verfügbaren Trainingsdaten vorliegt, oder die Kapazitäten für die Erstellung synthetischer Modelle vorhanden sind, sollte auf synthetisch erzeugte Trainingsdaten zurückgegriffen werden. Im vorliegenden Fall ist es bspw. nicht gelungen, den Sicherungsring so nachzubilden, dass dieser zuverlässig durch den Detektor erkannt werden kann.

## 4.6 Zusammenfassung der Detektionsergebnisse und Fazit

Um ein abschließendes Fazit zu ziehen, werden in **Tabelle 4.15** alle durchschnittlichen Qualitätswerte zu den jeweils durchgeführten Versuchen aufgelistet. Der Name eines Modells orientiert sich an den bekannten Namen, gefolgt von der genutzten Bildgröße im Training nach dem ersten Unterstrich und von der verwendeten Bildgröße in der Detektion. Die Höchstwerte werden grün hinterlegt. Die geringste Verlustrate erreicht das manuelle Modell mit einem Vertrauenswert von 0,3 in der Detektion. Bei dieser Einstellung werden die geringsten falsch negativen Detektionsergebnisse erreicht, weshalb der Recall an dieser Stelle den höchsten Wert der ganzen Versuchsreihe von 0,987 erreicht. Auf der anderen Seite liefert dasselbige Modell mit einem Vertrauenswert von 0,5 und 0,6 die höchsten Präzisionswerte im Durchschnitt. Insgesamt befindet sich der Höchstpunkt der globalen Genauigkeit bei den Detektionseinstellungen mit einem Vertrauenswertes von 0,4 und einer IoU-Schwellenwert von 0,5 bei einer Bildgröße von 800 Pixel in der Detektion.

Eine KI-Detektion mit einer Genauigkeit von 0,96 wird als zuverlässig gewertet, weil die meisten Objekte richtig erkannt werden. Mit Hilfe eines nachgeschalteten Algorithmus, welcher eine Plausibilitätsprüfung durchführt, kann die Zuverlässigkeit weiter erhöht werden. Darunter ist eine Prüfung zu verstehen, ob eine vorhandene Detektion logisch und zulässig ist. Um dies besser zu erklären, wird ein Beispiel angeführt. Bei der Detektion eines Lagers kann eine sinnvolle Plausibilitätsprüfung wie folgt aussehen. Wenn ein Rillenkugellager vorliegt, werden alle Detektionen der Klasse gegenseitig geprüft. Wird eine ungerade Zahl an Lagern erkannt, sollte überprüft werden, ob Detektionen vorliegen, die ähnliche Objekte wie zum Beispiel ein Schrägkugellager betreffen. Ist eine Detektion eines Schrägkugellager vorhanden, kann mit großer Sicherheit davon ausgegangen werden, dass hier eine falsch positive Detektion vorliegt. Neben der Anzahl an vorkommenden Detektionen bezüglich der Klasse Rillenkugellager können die Koordinaten überprüft werden. Vorher muss durch die Mittelung aller vorhandenen Detektionen eine Mittellinie bestimmt werden. Meistens sind pro Welle mindestens zwei Lager vorhanden, von denen vier Detektionen ausgehen. Anhand dieser Detektionen

kann geprüft werden, ob Durchmesser und axiale Position ähnlich sind. Darüber hinaus kann die Größe des Lagers mit Hilfe einer Normtabelle verifiziert werden.

Bei der Klasse RWDR kommt es häufiger als bei anderen Klassen zu falsch positiven Detektionen. Ein Abgleich der Anzahl der Detektionen und ein Größenabgleich können falsch positive Detektionen eliminieren. Es ist schwieriger auf Objekte zu schließen, welche nicht durch den Objektdetektor erkannt werden. Bei einer Passfeder kann dies zu Problemen führen, weil pro Bauteil nur eine Vorhersage ausgegeben wird. In diesem Beispiel kann die folgende Logik eingeführt werden, dass unter Zahnrädern (ausgeschlossen Ritzelwellen), unter denen keine Lager vorhanden sind, sowie am kleinsten Wellenabsatz eine Passfeder vorhanden sein muss. Diese Logik ist jedoch nicht immer auf andere Problemstellungen übertragbar. Die Detektionseinstellungen sollten bezüglich dieser Klassen priorisiert angepasst werden.

Der automatische Wellengenerator ist mit den beschriebenen Optimierungen, der Entfernung der Störgrößen sowie der Anpassung der Bildgröße, ein potenzielles Werkzeug, um die Detektionsqualität bei wenig vorliegenden Trainingsdaten zu erhöhen. Eine weitere Optimierung kann das Hinzufügen eines Gehäuses und die Anbindung der angrenzenden Bauteile, wie zum Beispiel das zweite Zahnrad des Zahnradpaars, im geschnittenen Zustand bis zum Bildrand sein.

Tabelle 4.15: Tabellarische Darstellung aller Ergebnisse im Durchschnitt

Modell	Verlustrate	Präzision	Recall	OA
Gemischt_800_800	0,174	0,926	0,826	0,775
Gemischt_half_1200_800	0,884	0,964	0,912	0,881
Manuell_800_1200	0,096	0,945	0,904	0,859
Manuell_1200_800	0,031	0,971	0,969	0,942
Manuell_1200_1200	0,029	0,971	0,971	0,944
Manuell_800_800, VW=0,3	0,013	0,95	0,987	0,938
Manuell_800_800, VW=0,5	0,055	0,998	0,945	0,943
Manuell_800_800, VW=0,6	0,094	0,998	0,906	0,904
Manuell_800_800, IoU=0,5	0,036	0,996	0,964	0,960
Synthetisch_800_800 ohne Störfunktion	0,167	0,950	0,833	0,798

In **Tabelle 4.16** sind die Optima der globalen Genauigkeiten zu den jeweiligen Klassen dargestellt. Fast alle Klassen erreichen den Wert eins. Die reale Darstellung des RWDR hat das Optimum der globalen Genauigkeit von 0,95 bei einem Vertrauenswert von 0,3 erreicht. Da die Präzision weiterhin den Wert eins annimmt, besteht das Potential den Vertrauenswert bezüglich dieser Klasse weiter abzusenken. Aus diesen Gründen des Potentials, die globale Genauigkeit weiter verbessern zu können, sind die Präzisionswerte

bei denjenigen Klassen mit angegeben, bei denen die globale Genauigkeit kleiner als eins ist. Hier besteht für alle Klassen Verbesserungspotential. Außerdem erreicht die Klasse Schrägkugellager den Wert 0,98 bei einem Vertrauenswert von 0,3, welcher sich aufgrund der Präzision von 0,98 nicht verbessern lässt. Ein Fokus eines zweistufigen Detektors auf Bauteilebene sollte entwickelt werden, damit die Lagerbauformen unterschieden werden können.

Tabelle 4.16: Zusammenfassung der erreichten Optima der einzelnen Klassen

Klasse	Optimum globale Genauigkeit
RWDR_real	0,95 (VW=0,3;Pre=1)
Wellenmutter	1,00
Sicherungsring	0,94 (VW=0,3;Pre=1)
Ritzelwelle	1,00
Zähne	1,00
Passfeder	1,00
Gewinde	1,00
Sicherungsblechnut	1,00
Wellenmutter mit Sicherungsblech	1,00
Schrägkugellager	0,98 (VW=0,5;Pre=0,98)
Rillenkugellager	1 (VW=0,3)
RWDR_einfach	1
Arithmetisches Mittel	0,9925

Da die Klasse RWDR\_real das Optimum der globalen Genauigkeit nicht erreicht hat, wird diese einer Überprüfung unterzogen. Dabei ist aufgefallen, dass die nicht detektierte realen Darstellung des RWDR auf Bauteile zurückzuführen ist, die nicht nach Norm in der TZ dargestellt wird. Die abgebildete Größe existiert nicht. Dies ist anhand der **Abbildung 4.49** zu sehen, indem die Darstellungen gegenübergestellt werden. In der Abbildung 4.49 ist ein RWDR abgebildet, welcher sich auf einem Wellendurchmesser von 20 mm befindet. Auf der anderen Seite ist in Abbildung 4.49 der RWDR dargestellt, welcher auf einem Wellendurchmesser von 30 mm sitzt. Da diese Größe des RWDRs weit entfernt von denjenigen Darstellungsgrößen des RWDRs aus dem Anlernprozess liegt, wird der unten abgebildete RWDR nicht erkannt. Werden diese Darstellungsfehler aus den Werten herausgerechnet, erreicht die Klasse RWDR einen globalen Genauigkeitswert von eins.

Bei der Klasse Schrägkugellager wird der globale Genauigkeitswert von eins nicht erreicht, da bis zu drei falsch positive Detektionen vorkommen. Bei diesen falschen Detektionen wird ein Rillenkugellager als Schrägkugellager markiert. Teilweise kommt dies vor, wenn Hilfslinien das Lager schneiden, sodass die wichtigen Elemente der

Lagerborden überdeckt werden. Allerdings kommen diese falsch positiven Ergebnisse auch vor, wenn der Detektor eine freie Sicht auf das Objekt hat. Hier ist in allen Fällen nur eine von vier Detektionen der Hauptlager auf der Welle betroffen, sodass diese falschen Ereignisse durch eine nachgeschaltete Logik herausgefiltert werden können. Diese Logik wird angewendet, bevor die lokalen Detektionen zurück in das ursprüngliche Bild übersetzt werden, d. h. wenn die Markierungen in die DIN A0 Zeichnung zurück übertragen werden.

Bei der Betrachtung der Detektionen des Sicherungsringes ist auffällig, dass drei Darstellungen des Sicherungsringes nicht durch den Detektor markiert werden, weil sich die geschnittene Seite auf der unteren Seite der Welle befindet. Der Sicherungsring ist auf einer Seite geschlitzt und wird deshalb auf einer Welle einseitig geschnitten dargestellt. Im Trainingsprozess werden ausschließlich die Darstellungen mit Schnitt oben verwendet. Der Wert des Sicherungsringes kann auf den Wert eins gesteigert werden, wenn diese Darstellung beim Anlernen mit berücksichtigt wird.



Abbildung 4.49: Detektierter RWDR (Normgröße) vs. Nicht detektierter RWDR

Im Durchschnitt kann mit den getesteten Werten laut Tabelle 4.16 eine globale Genauigkeit von 0,9925 erzielt werden. Wenn das Training bezüglich des Sicherungsringes sowie die nicht erkannte falsche Darstellung des RWDR mit berücksichtigt, kann das Optimum der globalen Genauigkeit weiter gesteigert werden. Wird dann noch eine Plausibilitätsprüfung implementiert, kann eine fehlerfreie Detektion angeboten werden. Das Ziel, eine zuverlässige Detektion von in TZ dargestellten Bauteilen mit Hilfe der KI zu erschaffen, wird erreicht. Eine Erkennung von weiteren Bauteilen in TZ ist grundsätzlich möglich.

Neben der Genauigkeit spielen die Präzision und der GIoU eine wichtige Rolle, da diese Kennwerte nicht nur die Klassifikation, sondern auch die Genauigkeit der Lokalisation mit einbeziehen. Diese Überprüfung werden in den Tests nicht mit berücksichtigt. Es wird zunächst die Klassifikation optimiert, um eine sichere Vorhersage über vorhandene Objekte zu erzielen. Um die Vorhersage von Position und Größe der Objekte besser vorhersagen zu können, müssten weitere Optimierungsschritte eingeleitet werden. Wie anhand der Trainingsauswertung zu den verschiedenen Modelle zu erkennen ist, werden hier Präzisionswerte von 0,5 bis 0,8 erreicht. Der mAP@0,5;0,95-Wert beträgt im schlechtesten Fall 0,5. Deshalb sind hier weitere Optimierungspotentiale vorhanden.

## 4.7 Gegenüberstellung der Detektionsergebnisse zu den Ergebnissen aus der Literatur

Die Modellergebnisse werden intrinsisch geprüft, indem sie mit anderen Modellen oder aufgezeichneten Daten verglichen werden. Darüber hinaus werden die Ergebnisse mit anderen wissenschaftlichen Quellen verglichen und auftretende Unterschiede analysiert. Dementsprechend wurden im Stand der Technik Detektionen anhand der Grabcut-Segmentierung vorgestellt. Diese erreichten im Idealfall Genauigkeitswerte von knapp über 0,8. In diesem Fall wurde die Detektion von Früchten analysiert. Es gibt jedoch bereits Veröffentlichungen, welche bei einer solchen Detektion von Obst eine höhere Genauigkeit mit Hilfe der KI erreichen [BK21]. An die im vorherigen Kapitel analysierten Ergebnisse kommt keine verfügbare Softwarebibliothek der Computer Vision wie zum Beispiel *OpenCV* heran, um Bauteile in TZ erkennen zu können. Wenn ideale Größenverhältnisse gegeben sind und die standardisierten Bauteile stets die gleiche Größe und Orientierung aufwiesen, kann eine Bilderkennungsstrategie ähnliche Ergebnisse erzielen. In der Analyse der Detektionsentwicklung hat sich herausgestellt, dass eine Skalierungs- und Orientierungsunabhängigkeit gegeben sein muss, damit eine zuverlässige und präzise Detektionsgüte mit entsprechender Wiederholgenauigkeit gegeben ist. Daher wird eine KI-gestützte Detektion empfohlen, um eine optimale Objekterkennung bereitstellen zu können.

Außerdem ist ein Vergleich mit den im Stand der Technik beschriebenen Entwicklungen zur KI-gestützten Objektdetektion interessant. Die Firma Werk24 hat eine Anwendung entwickelt, die Schriftfelder, Bemaßungen und Toleranzen identifizieren und auslesen kann. Hier ist auffällig, dass Buchstaben und Symbole recht zuverlässig erkannt werden. Demgegenüber werden Durchmesser- sowie Toleranzzeichen nicht zuverlässig erkannt. Dies kann daran liegen, dass eine Bibliothek für das Training genutzt wird, welche diese seltenen vorkommenden Symbole nicht berücksichtigt. Diese Symbole können wie in der vorliegenden Analyse mit in das Training integriert werden, damit eine bessere Detektionsqualität erreicht wird. Außerdem ist dieses Beispiel ein eher einfach gewähltes Anwendungsbeispiel, da dieses Zeichnungsformat klein ist. Bei größeren Zeichnungsformaten nimmt die Detektionsqualität deutlich ab, sodass die Nutzung eines zweistufigen Detektors zweckmäßig ist. Da zu diesem Angebot keine Analyseergebnisse mit Qualitätsparametern vorliegen, kann die Detektionsgenauigkeit nur abgeschätzt werden. Beim Vorliegen eines Zeichnungsformates einer DIN A3 Zeichnung oder kleiner kann im Optimalfall eine durchschnittliche globale Genauigkeit von 0,95 erreicht werden.

Eine weitere Veröffentlichung hat die Detektionsqualität der Objekterkennungsalgorithmen *RetinaNet*, *SSD* und *YOLO* in Bezug auf technische Zeichnungen miteinander verglichen. Es werden mAP-Werte von 0,7947 (*RetinaNet*), 0,5821 (*YOLO*) und 0,2633

(*SSD*) erreicht (siehe Unterkapitel 2.8). In dieser Arbeit wird gezeigt, dass *YOLO* eine wesentlich höhere Genauigkeit erreichen kann, wenn die getroffenen Optimierungen durchgeführt werden. Die eben genannten Werte werden deutlich übertroffen. Der erwähnte Wert von 0,5821 in Bezug auf *YOLO* kann mit einer einstufigen Detektion durchaus erreicht werden und wird als realistisch bewertet, weil dieser sich mit den Werten aus der durchgeführten Voruntersuchung deckt.

Insgesamt kann kein ausführlicher Vergleich zu anderen KI-gestützten Objekterkennungen vollzogen werden, da wenig Literatur gerade in Bezug auf TZ vorhanden ist. Insgesamt existieren wenige anwendungsnahe Veröffentlichungen zur KI-Objekterkennung, womit die in dieser Arbeit erzielten Kennwerte verglichen werden können. Darüber hinaus ist ein Vergleich mit der hier genutzten Anwendung oft nicht sinnvoll oder angemessen. Durch eine Verwendung neuerer Versionen von *YOLO* sollten nur geringe Verbesserungen möglich sein.

# 5 Anforderungen des Technischen Zeichnens an den Ingenieur

Für die Bestimmung von Kompetenzniveaus wird auf die Analyse mit Hilfe von didaktischen Methoden zurückgegriffen, die zur Einstufung der Kompetenzen von Lernenden (in der Hochschullehre) genutzt werden. Hierzu werden innerhalb der Förderrichtlinie OERContent.nrw (digitale) Lehr-/Lernmaterialien im Zuge des Projektes *TZ Digital.nrw* aufbereitet und digitalisiert. Während dessen wurden auch verschiedene Lenzieltaxonomien erarbeitet und festgehalten, mit denen das Niveau eines Studierenden bestimmt werden kann.

Während der Erstellung der öffentlichen Lehr-/Lernmaterialien wurden verschiedene Anforderungen und Regularien festgehalten, die bspw. für die Veröffentlichung von Materialien unter freier Lizenz gegeben sein müssen. Dies ist interessant für die öffentliche Bereitstellung der KI später. Deshalb werden in diesem Unterkapitel die dafür wichtigen Schritte untersucht und für den weiteren Verlauf der Arbeit aufbereitet. Die ausführliche Analyse des Studiums rund um das Modul Technisches Zeichnen wird durchgeführt, um eine möglichst allgemeingültige Bewertungsskala aufstellen zu können.

## 5.1 Anforderungen in der Lehre des Technischen Zeichnens

In diesem Unterkapitel werden die verschiedenen Anforderungen der beteiligten Akteure an die Lehre des Technischen Zeichnens analysiert, damit im nächsten Schritt die Kompetenzstufen definiert werden können. In **Abbildung 5.1** sind die Aktivitäten rund um die Lehrveranstaltung gezeigt, und wie diese zusammenhängen. Das Dreieck besteht aus den wichtigen Säulen Lernergebnisse, Lernaktivitäten und Prüfungsformen. In den Lernergebnissen sollen diejenigen Kompetenzen aufgeführt werden, welche beruflich und fachlich getrieben sind. Die Prüfungsform gibt an, wie die Prüfung gestaltet werden muss, um das Vorliegen der Kompetenzen geeignet prüfen zu können.

Für die Analyse der Anforderungen wurden Evaluationen mit Studierenden und Lehrenden durchgeführt, um einen IST-Stand zum Start des Projektes *TZ Digital.nrw* festzustellen, sowie eine Abschlussevaluation am Ende des Projektes zur Ermittlung der Änderung des Ausgangszustandes. Die Evaluation beinhaltet Umfragen (mittels

Fragebögen), die mit dem digitalen Umfragesystem Limesurvey der TU Dortmund durchgeführt wurden, sowie Interviews.

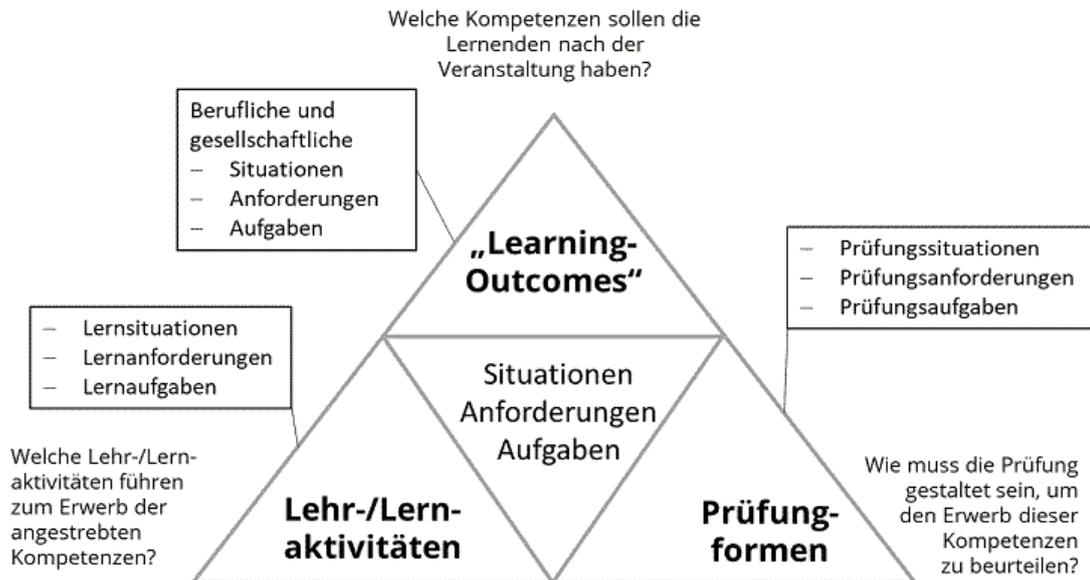


Abbildung 5.1: Anforderungen des *Constructive Alignment* [WW11]

An dieser Evaluation sind zwölf Hochschulen aus Nordrhein-Westfalen involviert, davon sechs die dem Konsortium von *TZ Digital.nrw* angehören und weitere fünf Projektpartner\*innen des erweiterten Entwicklungskreises. 257 Studierende sowie zwölf Hochschullehrende haben an der Evaluation teilgenommen. Die **Abbildung 5.2** zeigt, welche Aspekte die initiale Umfrage beinhaltet. Aus den Bedingungen für die Lehr-/Lerninhalte und Lernziele werden Methoden und Medien erarbeitet, die der gesamten Lernorganisation dienen. [DF22, BDFW21, DK22]

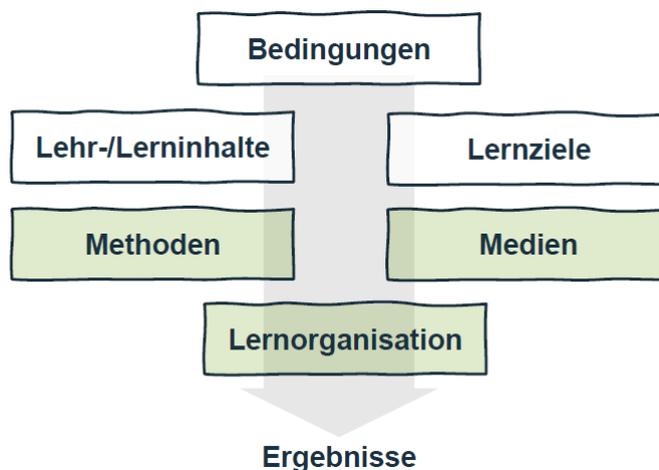


Abbildung 5.2: Aspekte der einführenden Erhebung nach Kerres [Ker18] in Anlehnung an Peterßen [Pet06]

### 5.1.1 Analyse der Modulhandbücher und Prüfungsordnungen in NRW

In diesem Abschnitt werden die studienspezifischen Anforderungen diskutiert, da ein großes Spektrum an Studiengängen (ca. 18) mit unterschiedlicher fachlicher Tiefe in Bezug auf das Modul TZ an verschiedenen Hochschulen vorliegt. Der zeitliche Umfang beträgt zwei bis sechs Semesterwochenstunden (SWS), wobei die Mehrheit (ca. 70%) der Hochschulen in NRW dafür drei oder vier SWS anberaumt. Dies belegt eine Analyse der vorliegenden Modulhandbücher und Prüfungsordnungen, in der 29 Hochschulen aus NRW gegenübergestellt werden (siehe Anhang C und Anhang F Abbildung F.1). Für das Modul Technisches Zeichnen werden in NRW zwei bis sechs Credit Points (CP) bzw. Leistungspunkte (LP) vergeben. Das Fach ist in die Studieneingangsphase hauptsächlich im ersten und zweiten Semester (Anteil 3/4 im Konsortium) oder dritten und vierten Semester (Anteil  $\frac{1}{4}$  eingegliedert. Es werden mittlere bis große Teilnehmendenzahlen bis 100 (fünf Standorte), bis 200 (drei Standorte) und bis 500 (drei Standorte) adressiert. Darüber hinaus hat die NRW-weite Analyse ergeben, dass 43 bis 270 Stunden als Workload für das Fach eingeplant sind, wobei die meisten Hochschulen in NRW dafür 150 Stunden vorsehen (siehe Anhang F Abbildung F.3). Das Prüfungsformat ist mehrheitlich eine schriftliche Klausur am Ende des Semesters.

### 5.1.2 Anforderungen der Lehrenden

Der Fokus der Lehrenden liegt auf unmittelbarem und oft synchronem Austausch (feste Veranstaltungszeit) zwischen Dozierenden und Studierenden. Es werden folgende Möglichkeiten für die Klärung von Fragen angeboten:

- Vorlesungen (7x),
- Übungen (7x),
- Sprechstunden nach Anfrage (7x),
- Forum (6x).

Oftmals werden „klassische“ Formate wie Vorlesungen mit Foliensätzen (7x), Übungen mit Übungsaufgaben (4x), ein ausformuliertes Skript (4x) sowie ein Lehrbuch (4x) genutzt. Es wird aber auch auf digitale Formate wie Videos von Vorlesung und Übung (7x), Tests/Quiz (4x) und 3D-PDF (4x) zurückgegriffen. Bei dem summativen Assessment wird innerhalb des Konsortiums eine Klausur (Anteil 3/4) gegenüber einem Fachgespräch angewendet, während bei anderen Prüfungsformaten (Anteil  $\frac{1}{2}$  Teilleistungen bzw. Voraussetzungen für die Prüfung (mit und ohne Wertung in abschließender Note) genutzt werden. Die Lehrinhalte werden über die Lern Management Systeme (LMS) *Moodle* und *Ilias* bereitgestellt.

Die fachlichen Anforderungen für das weitere Studium sowie für die spätere Profession sind sehr ähnlich. Studierende sollen die Grundzüge des methodischen Konstruierens kennenlernen und die Regeln für das Technische Zeichnen erlernen, damit Ideen skizziert und verständlich erklärt werden können. Die sichere Bedienung eines CAD-Systems ist erforderlich. Die normgerechte Darstellung technischer Elemente und Komponenten sowie das selbstständige Lesen der Zeichnungen von Einzelteilen und technischen Baugruppen, um komplexe Aufgabenstellungen der modernen Konstruktionspraxis zu lösen, gehört zu den Grundfertigkeiten eines Ingenieurs bzw. einer Ingenieurin. Dabei werden die folgenden Inhalte behandelt:

- Einordnung in den Konstruktionsprozess,
- Grundlagen der Freihandzeichnungen,
- Ansichten und Dreitafelprojektion,
- Bemaßung,
- Schnitte und Zeichnungsgruppen,
- Normung/GPS (Geometrische Produktspezifikation),
- Toleranzen und Passungen,
- Normteile und Maschinenelementen insbesondere Schraubenverbindungen,
- Wellenbearbeitung,
- CAD,
- Lesen und Interpretieren Technischer Zeichnungen (Einzelteilzeichnungen und Baugruppenzeichnungen),
- Verstehen und Erstellen von Anforderungs- und Stücklisten,
- Berechnungsgrundlagen.

Die im Projekt *TZ Digital.nrw* entwickelte Lernkarte ist in **Abbildung 5.3** dargestellt. Hier erhält man eine Übersicht über die Themen und kann sich gleichzeitig über die Informationsicons weitere Erklärungen und Verlinkungen zu den jeweiligen Themen einholen. Die einzelnen Themen werden als Häuser dargestellt und enthalten in der Nähe Grafiken, welche symbolisch für das jeweilige Thema sind. Möglich gemacht wird diese Interaktion durch das *Moodle*-Plugin H5P, welches interaktive Elemente wie Hot-Spot-Aufgaben bereitstellt. Bei Hot-Spot-Aufgaben müssen interessante Bereiche gefunden und markiert werden. Beispielsweise lassen sich dadurch Fehlersuchaufgaben realisieren, indem die Fehler vorher im Bild als Hot-Spot angegeben werden.

Der Fortschritt wird über einen Fortschrittsbalken, welcher sich unten rechts im Bild befindet, sowie über einen menschenähnlichen Avatar, welcher den markierten Lernweg

entlang wandert, visualisiert. Der Fortschritt wird über den erfolgreichen Abschluss von Moodle-Tests verfolgt. Wird eine Bestehensgrenze von 90% richtigen Antworten erreicht, gilt eine Kompetenz als erreicht. Dies wird dann als ein erfolgreiches Abschließen eines Themenbausteins abgehakt. Die visuellen Hinweise an den Häusern geben Aufschluss über das jeweilige Thema an. Nachteil dieser Lernlandkarte ist, dass sie nur für einen bestimmten Lernweg verwendet werden kann. Für andere Lernwege müssen Anpassungen vorgenommen werden.

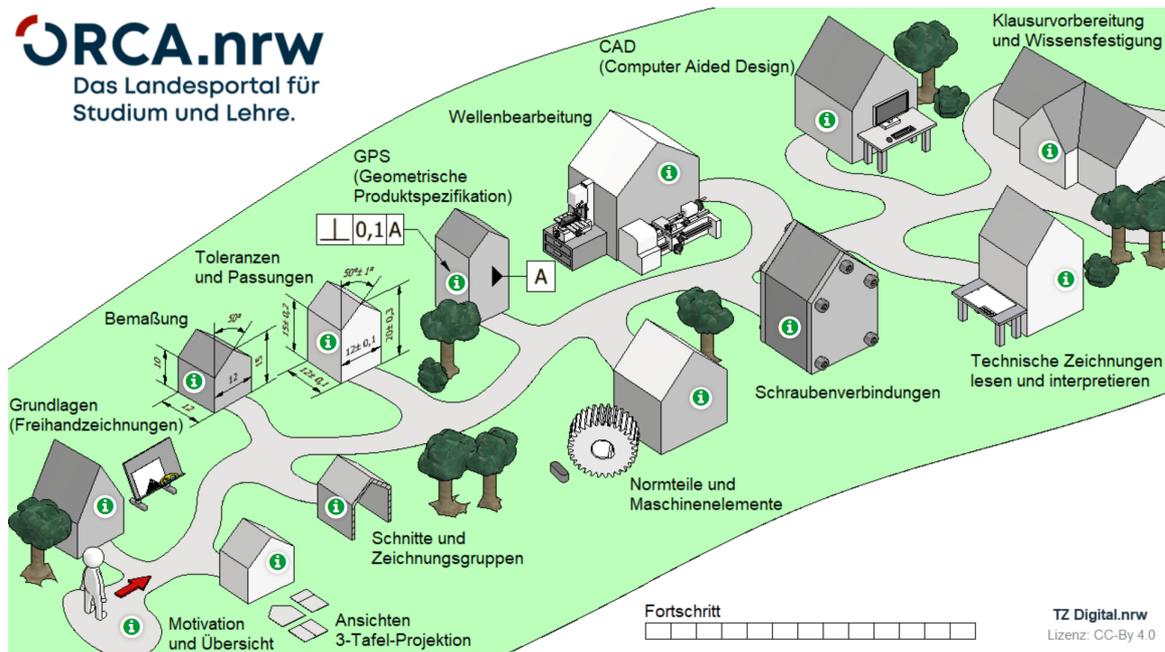


Abbildung 5.3: Interaktive Lernlandkarte als Themen- und Inhaltsübersicht

Insgesamt bietet die Lernlandkarte einen übersichtlichen und schnellen Themenüberblick. Außerdem handelt es sich um ein spielerisches Element, weil u.a. der Fortschritt laufend aktualisiert wird. So wird die Motivation, die Themen abzuschließen, erhöht. Es hat sich außerdem gezeigt, dass Studierende den Aufbau von Lehrveranstaltungen besser nachvollziehen können und die Vorbereitung auf diese vereinfacht. Die Autonomie der Studierenden wird erhöht und sie können ihren Lernweg selbst gestalten. Dies wird anhand einer Metapher verdeutlicht. In den vergangenen Jahrzehnten der Lehre haben die Lehrenden (z. B. Professor\*in) die Navigation übernommen, da diese als einzige im Besitz der Landkarte waren. Die Studierenden mussten folgen. Nun können sie den Lernweg zur Klausur eigenständig erkunden.

### 5.1.3 Anforderungen der Studierenden

Die Anforderungen der Studierenden werden anhand einer initialen Befragung zur Lernsituation im Jahr 2020 sowie anhand einer Abschlussevaluation aus dem Jahr 2023 analysiert. Befragt wurden sowohl die Studierenden als auch die Lehrenden.

Beide Befragungen waren Teil des Projektes *TZ Digital.nrw* und sind in der Lage, die Veränderung des Ausgangszustands, auch aufgrund der nun vorliegenden OER als Ergänzung zu den Lehr-/Lernmaterialien, darzustellen. In Umfragen wird jeweils die *Likert-Skala* (1-5) angewendet.

Die initiale Befragung richtet sich an Studierende höherer Semester, welche einschätzen können, wie der fachliche Bedarf im weiteren Verlauf des Studiums aussieht. Da sich die meisten Umfrageteilnehmenden in einem höheren Studiensemester befinden, ist davon auszugehen, dass sie die Abläufe von Lehrveranstaltungen und Klausuren kennen und ihre Stimmabgabe im Kontext des Gesamtstudiums erfolgt ist (siehe Anhang D Abbildung D.1(a)). Diese These wird durch die Tatsache unterstützt, dass die Mehrheit bereits die Klausur im Modul Technisches Zeichnen abgelegt hat (siehe Anhang D Abbildung D.1(b)).

Bei der Abfrage des Arbeitsaufwandes für das Fach TZ ergibt sich annähernd eine Gleichverteilung um den Wert drei (siehe Anhang D Abbildung D.2). Demgegenüber gehen die Meinungen zu den genutzten Medien weit auseinander (siehe Anhang D Abbildung D.3). Während die mediale Aufbereitung von einem Teil der Studierenden als gut bis sehr gut bewertet wird, bewertet eine ähnliche Anzahl der Studierenden die Aufbereitung als eher schlecht. Der Aspekt der genutzten Medien scheint ein wichtiges Thema zu sein, in dem noch Potential steckt.

Bei der Einschätzung nach dem Schwierigkeitsgrad gehen die Meinungen auseinander, obwohl der Mittelwert exakt bei drei liegt. Wie im vorherigen Kapitel beschrieben, empfinden einige die Lehrinhalte als eher schwierig, aber ebenso viele die Inhalte als eher einfach. Dies liegt an dem unterschiedlich ausgeprägten Vorwissen. Einige Studierende starten Ihr Studium mit einer abgeschlossenen Berufsausbildung (bspw. als technische/r Produktdesigner/in) oder haben ein Grundpraktikum absolviert, während andere keinerlei Vorwissen mitbringen. An dieser Stelle bietet sich das *Constructive Alignment* als didaktische Methode an, weil die Lerninhalte je nach Kenntnisstand ausgewählt werden können. Die Lehrinhalte werden so ausgelegt, dass die Studierenden ohne Vorwissen mitberücksichtigt werden.

Zu der Themenpriorisierung sehen die Verteilungen ähnlich aus (siehe Anhang D Abbildung D.4). Vor allem werden die Themen Toleranzen und Passungen, TZ sowie Normteile für den weiteren Studienverlauf als sehr wichtig bewertet. Die Normung selbst wird als nicht so wichtig angesehen, sollte jedoch laut der Aussage der Studierenden weiter als Thema in den Veranstaltungen behandelt werden. Bei den genannten Themen sind sich also beide Seiten, sowohl Studierende als auch Lehrende, einig, dass es sich bei den Inhalten im Ingenieurwesen studiumsunabhängig um absolute Grundkenntnisse eines Ingenieurs bzw. einer Ingenieurin handelt.

In Bezug auf die Gewichtung eines Themengebietes liegt der Durchschnitt bei allen Themen bei über drei (siehe Anhang D Abbildung D.5). Eine größere Gewichtung aller Themen führt zu einem höheren Gesamtumfang. Daraus kann die Schlussfolgerung gezogen werden, dass zumindest die wichtigsten Inhalte an Umfang zunehmen sollen, auch wenn der Gesamtumfang dadurch zunimmt. Laut den Umfrageergebnissen bietet es sich an, die Themen Normteile und Toleranzen und Passungen mehr zu gewichten. Es hat sich aus den Erfahrungen der Lehrenden des Konsortium (*TZ Digital.nrw*) herausgestellt, dass besonders das Thema Toleranzen und Passungen im weiteren Studienverlauf zu Problemen führt, weil offenbar Grundlagen nicht richtig verstanden worden sind.

Abschließend wird die Frage nach dem Wunsch der digitalen Aufbereitung näher betrachtet. Das Thema Normung wird von den Studierenden als nicht so wichtig angesehen. Besonders das Thema Normteile bietet sich an, weil sich eine Verknüpfung von TZ zur 3D-Darstellung anbietet. Zum Thema Toleranzen und Passungen können Probleme wie die Doppelpassung, aber auch andere grundlegende Aspekte, digital besser dargestellt werden. Anhand der zuletzt genannten Themen ist die Kritik an den eingesetzten Medien durchaus berechtigt, weil hier nicht das volle Potential der vorhandenen digitalen Medien ausgenutzt wird (Stand Anfang Covid-19 Pandemie). Dies geht besonders aus der initialen Befragung und Analyse hervor.

Die initiale Befragung hat ergeben, dass Studierende das Thema CAD als das wichtigste Thema zurückmelden und Freihandzeichnungen als unwichtig betrachten, sodass es ihrer Meinung nach aus dem Lehrplan gestrichen werden sollte (siehe Anhang D) – Anmerkungen der Studierenden). Hier widersprechen die Lehrenden dieser Aussage vehement, da dies ein wichtiges Verständigungsmittel ist und so Ideen schnell und einfach skizziert werden können. Ein weiterer häufig genannter Vorschlag der Studierenden ist die Nutzung von 3D-Brillen. Die bezieht sich vermutlich auf die Nutzung der *Extended Reality* (XR) Technologie wie z. B. *Virtual Reality* (VR).

An der durchgeführten Abschlussevaluation haben 51 Studierende teilgenommen. Die meisten Studierenden gehören der Studienrichtung Bachelor Maschinenbau an, befinden sich im ersten Semester und sind männlich (siehe Anhang E Abbildung E.1(a), Abbildung E.1(b) und Abbildung E.2(a)). Außerdem gibt die Mehrheit an, keine Erfahrungen oder Vorkenntnisse in Bezug auf TZ zu haben (siehe Anhang E Abbildung E.2(b)). Die meisten Studierenden finden die Nutzung von OER vorteilhaft und sehen die gemeinsame Entwicklung von OER als positiv an (siehe Anhang E Abbildung E.3(a) und (b)). Ca. 47% finden, dass der Einsatz von OER ein guter Ersatz für Lernmaterialien ist, wobei die Vorteile eher in der Ergänzung zu sehen sind (siehe Anhang E Abbildung E.4(a) und (b)).

Die Verteilungen zur Beurteilung der Wichtigkeit der einzelnen Themen Konstruktionsprozess, zielorientierte Bemaßung, Schraubenverbindungen, Toleranzen und Passungen

und Wellenbearbeitung sind ähnlich, sodass sie als wichtig empfunden werden. Die Themen Normteile und Maschinenelemente sowie CAD stechen dabei besonders heraus und werden als besonders wichtig empfunden (siehe Anhang E Abbildung E.7(b) und Abbildung E.9(b)). Das gleiche Bild zeigt sich bei der Frage nach der Gewichtung des Umfangs, wobei hier das Erstellen von Freihandzeichnungen herausragt, weil es weiterhin weniger behandelt werden soll, während die meisten trotzdem angeben, dass der Umfang wie bisher gleich bleiben solle. Im Vergleich zur initialen Befragung hat die Zustimmung für das Freihandzeichnen teilweise zugenommen.

Bei der Frage nach der Anwendbarkeit der Themen geben die meisten Studierenden an, dass sie die Themen nach Beendigung des Semesters gut beherrschen. Es fällt jedoch auf, dass die Fähigkeiten in Bezug auf CAD und GPS nicht so gut bewertet werden (siehe Anhang E Abbildung E.17 und Abbildung E.24). Beim Thema GPS liegt es daran, dass es an einigen Standorten nicht Teil des Lerninhaltes ist.

Während des Semesters wurde ein *Moodle*-Kurs mit OER-Lerninhalten für die Studierenden bereitgestellt. Die Einschreibungen belaufen sich auf über 350 Studierende, wobei zusätzlich Gastzugänge ohne Authentifizierung genutzt werden. Dies zeigt, dass die Studierenden mit dem zusätzlichen Angebot gearbeitet haben. In den Umfragen gab die Mehrheit jedoch an, die Inhalte zu den verschiedenen Themen nicht genutzt zu haben (siehe Anhang E). Diejenigen, die die Lerninhalte genutzt haben, bewerteten die mediale Aufbereitung und Interaktivität als positiv, sodass diese beim Lernen und bei der Vorbereitung auf die Prüfung als gute Ergänzung angesehen werden. Insgesamt wird die Einbindung von OER in die Lernmaterialien begrüßt (siehe Anhang E Abbildung E.75(a) und (b)). Aufgrund der geringen Nutzung kann an dieser Stelle geschlussfolgert werden, dass ein freiwilliges Angebot außerhalb der Lehrveranstaltungen eher weniger genutzt wird. Hier sind die Lehrenden gefragt, indem sie die Materialien direkt in die Lehrveranstaltung einbinden. Die Nutzung kann außerdem angeregt werden, wenn sich Hochschulen bereit erklären, für das Absolvieren dieses Kurses ECTS-Punkte zu verteilen.

### 5.1.4 Didaktische Rahmenbedingungen

Aus den Anforderungen des Digitalisierungsprojektes lassen sich didaktische Anforderungen an die Lehrmaterialien entnehmen, die hier aufgeführt werden:

- Extrinsische und intrinsische Anreizsysteme,
- Zielgruppenanpassung,
- Evaluation,
- Lernziele,

- Lerninhalte,
- Nachhaltigkeit,
- Blended-Learning geeignet.

Über fachspezifische Lernziele hinaus können auch fachübergreifende Lernziele mit zunehmenden Allgemeinheitsgrad formuliert werden, nämlich inhaltlich-fachliche Lernziele, methodisch-problemlösende Lernziele, sozial-kommunikative Lernziele und affektiv-ethische Lernziele [Ott11; May09]. Unter Berücksichtigung der genannten Aspekte können auch andere Fächer und spätere Arbeitsgebiete berücksichtigt werden.

Im Jahr 2011 wurde ein gemeinsames Bewertungsraster für das Technische Zeichnen vorgeschlagen [Met11]. Dieser Vorschlag sieht vor, ein „Raster für die Bewertung der Lernniveaus des technischen Zeichnens“ für den Europäischen Qualifikationsrahmen (EQR) zu entwerfen [Met11]. Didaktische Konzepte können auf diesen Lernniveaus aufbauen. Um kompetenzorientiertes Lernen zu gestalten, wird das Prinzip des *Constructive Alignment* später verwendet, um Lernziele, Bewertungsaufgaben und Lehr-/Lernaktivitäten aufeinander abzustimmen [BT11]. Zu diesem Thema nutzen nur zwei Standorte aus dem Konsortium Lernziele, die über das Modulhandbuch hinaus formuliert werden.

### 5.1.5 Weitere Anforderungen

Weitere Anforderungen ergeben sich aus der Förderrichtlinie OERContent.nrw sowie der OER-Plattform ORCA.nrw. Laut der Handreichung sind Lizenzen zu vergeben, wenn lizenziertes Material genutzt wird. Die Lizenz ist für Nachnutzende stets zu nennen und soll nach der TULLUBA-Regel (siehe **Abbildung 5.4**), welche auch unter dem Namen TULLU-Regel bekannt ist, die folgenden Informationen beinhalten: Titel, Urheber\*innen, Lizenz (inkl. Version der Lizenz), Link zum Lizenztyp und der Ursprungsort (Link zum Original). „Die grundsätzliche Empfehlung lautet, dass Lizenzhinweise immer gut leserlich platziert sein sollen“. [ORC22]

Das Material soll neben der Barrierefreiheit unbedingt mit Metadaten verknüpft werden, damit es bestmöglich für andere auffindbar und nachnutzbar ist (z. B. in Suchmaschinen *Open Educational Resources Search Index* (OERSI) etc.). Dabei werden die inhaltlichen und formalen Merkmale der Materialien dargestellt. Die Metadaten implizieren dabei den Titel des Materials, die Urheber\*in (Name, Akademischer Grad und Hochschule), die Fachbereiche, die Lizenz, die Sprache, den Medientyp und das Förderprogramm. Optionale Angaben sind sonstige Beitragende, Schlagwörter, und die Kurzbeschreibung. „Die Metadaten basieren auf dem Allgemeinen Metadatenprofil für Bildungsressourcen (AMB)“. [ORC22]



Abbildung 5.4: TULLU-Regel zur Angabe von Metadaten [BMM16]

## 5.2 Modularer Aufbau des Lehr-/Lernangebots

Das *Constructive Alignment* sieht eine Aufteilung des Materials nach der Komplexität vor (siehe Abbildung 2.3). Im Projekt *TZ Digital.nrw* wird anhand eine modulare Struktur für das Lehr-/Lernmaterial entwickelt, damit die Inhalte flexibel genutzt werden können. Der modulare Aufbau wird neben der Einteilung nach Thema durch die eindeutige Trennung der Komplexitätsstufen erreicht. Damit diese Einteilung weder zu lokal noch zu grob ausfällt, werden die Taxonomiestufen in drei verschiedene Schwierigkeitsgrade aufgeteilt (siehe **Abbildung 5.5**).

Also werden die folgenden Kategorien zur Staffelung der fachlichen Tiefe (Kompetenzniveaus) je Thema definiert, damit eine Bewertung des Niveaus vollzogen werden kann:

- I. Geringer fachlicher Anspruch (Nebenfächer und weniger technische geprägte Studiengänge, Überblicksebene) – Einfach
- II. mittlerer fachlicher Anspruch (deutlich technisch geprägter Studiengang, Anwendungsebene) - Mittel
- III. Hoher fachlicher Anspruch (hohe technische Spezialisierung, Entwicklungsebene) - Schwer

Komplexität	<b>Erinnern</b>	aufzählen, definieren, berichten, identifizieren, darstellen, bezeichnen, sammeln, sichten, tabellarisieren, zitieren, benennen, erkennen, ...	Einfach
	<b>Verstehen</b>	beschreiben, gegenüberstellen, abschätzen, verknüpfen, unterscheiden, einschätzen, diskutieren, erweitern, interpretieren, veranschaulichen, klassifizieren, zusammenfassen, ...	
	<b>Anwenden</b>	vorführen, berechnen, vervollständigen, abbilden, lösen, modifizieren, einen Zusammenhang herstellen, verändern, anwenden, experimentieren, entdecken, ausführen,	Mittel
	<b>Analysieren</b>	auffrennen, ordnen, verbinden, kategorisieren, anordnen, analysieren, unterteilen, systematisch vergleichen, differenzieren, strukturieren, ableiten, beimessen, ...	
	<b>Evaluieren</b>	beurteilen, entscheiden, einstufen, werten, erproben, messen, empfehlen, evaluieren, überzeugen, überprüfen, kritisch bewerten, herausfiltern, einschätzen, unterschiedlich behandeln, untermauern, schließen, argumentieren, ...	Schwer
	<b>Erschaffen</b>	entwickeln, planen, produzieren, kombinieren, integrieren, umgestalten, ersetzen, erstellen, gestalten, erfinden, mit Annahmen arbeiten, zusammensetzen, ausarbeiten, bereitstellen, verallgemeinern, umformulieren, erzeugen, ...	

Abbildung 5.5: Einteilung der Komplexitätsstufen nach [Dil23c]

Die einfache Komplexitätsstufe sieht vor, dass das Verständnis für die Themen gelehrt wird. Die zweite mittlere Stufe soll die Fähigkeit der Anwendung und die Analysefähigkeit stärken. In der letzten und schwierigsten Komplexitätsstufe wird das selbstständige Erarbeiten von Lösungen anhand von komplexen Aufgaben berücksichtigt.

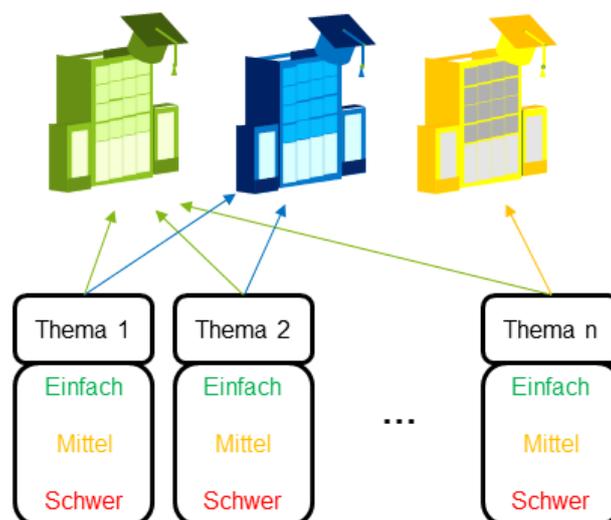


Abbildung 5.6: Organisationsstruktur der Lehr-/Lerninhalte

Mit dieser Organisationsstruktur, welche in **Abbildung 5.6** visualisiert ist, werden die Lehr-/Lerninhalte in den MOOC als OER eingebunden, damit eine Berücksichtigung aller Anforderungen gewährleistet wird. Lehrende können bei dem Vorliegen der beschriebenen Struktur wählen, welche Inhalte sie auswählen möchten, um ihren eigenen individuellen Kurs nach den Anforderungen der jeweiligen Hochschule erstellen zu können.

Je nach Vertiefungsrichtung, welche der Standort anbietet, können die für den späteren Studienverlauf benötigten Themen in einem höheren Grad fachlicher Tiefe behandelt werden. Bietet eine andere Hochschule andere Ingenieurstudiengänge an, werden vermutlich nicht alle Themen des Technischen Zeichnens benötigt, sodass Themen außen vor gelassen werden können und trotzdem nach fachlicher Tiefe gefiltert werden kann. Ein weiterer Vorteil der öffentlichen Bereitstellung ist, dass wenn sich Studierende für ein Thema interessieren und es an einem Hochschulstandort nur in geringer fachlicher Tiefe oder gar nicht behandelt wird, sie sich weiter darüber informieren und das Thema abhandeln können.

Darüber hinaus bietet dieses digitale Angebot mit dem beschriebenen Aufbau den Vorzug, dass es mit aktuellen Lehrkonzepten vereinbar ist. Eine direkte Verknüpfung mit dem Blended Learning ist möglich, welches die Präsenzlehre und Onlinephasen vereint. Außerdem ist es mit dem „Flipped Classroom“ Ansatz kombinierbar. Hier werden die niedrigen Komplexitätsstufen als Selbstlerneinheit zur Verfügung gestellt und eine tiefergehende Diskussion und Evaluation der Lerninhalte findet in Gruppen statt. Durch die Bereitstellung der einfachen und mittleren Komplexitätsstufen durch den öffentlichen *Moodle*-Kurs können sich die Studierenden die Lerninhalte online selbst aneignen, bevor eine intensivere Abhandlung erfolgt. [Dil23b]

Zuletzt ist der modulare Aufbau auch mit Spielkonzepten, die in der Lehre verwendet werden, vereinbar (siehe Unterkapitel 2.5). Die definierten Lernziele können für das Spielkonzept als primäres oder sekundäres Spielziel genutzt werden. Wenn ein Lernspiel erstellt wird, bei dem alle Lernziele gleichzeitig adressiert werden, würde der modulare Aufbau ad absurdum geführt. Besonders eignen würden sich das Einbinden spielerischer Elemente anbieten, bei denen das Lernziel im Vordergrund steht.

### 5.3 Definition der Kompetenzstufen

In diesem Unterkapitel werden die Anforderungen an den Ingenieur bzw. die Ingenieurin in Bezug auf TZ anhand der zuvor eruierten Lernziele des *Constructive Alignment* definiert. Das Ausformulieren der Kompetenzniveaus erfolgt anhand des Standes der Technik (siehe Unterkapitel 2.4). Es werden teilweise Definitionen für Kompetenzstufen

aus dem Projekt *TZ Digital.nrw* extrahiert, aufbereitet und in der Formulierung und dem Erfüllungsgrad bzgl. des *Constructive Alignment* optimiert.

### 5.3.1 Einordnung in den Konstruktionsprozess

Die Themen des Technischen Zeichnens werden in diesem Unterpunkt in den Kontext des Konstruktionsprozesses eingeordnet. Dieses Themengebiet enthält nur ein Kompetenzniveau, wie im Folgenden beschrieben.

I. Geringer fachlicher Anspruch – Einfaches Niveau:

Die Studierenden sind in der Lage, eine TZ in den Produktentwicklungsprozess einzuordnen und deren Bedeutung für diesen zu beschreiben. Sie können benennen, von welchen Akteuren die Anforderungen aufzunehmen sind und wem die TZ in der weiteren Prozesskette zu übergeben ist, damit ein Produkt hergestellt werden kann. Dadurch kann auch die Wichtigkeit der TZ für den gesamten Konstruktionsprozess erklärt werden.

### 5.3.2 Grundlagen der TZ und Freihandzeichnungen

Das Thema Grundlagen der TZ und Freihandzeichnungen behandelt Linien, Ansichten, Schriftfelder, Bemaßung, Stückliste, Faltung und Axonometrien grundlegend. Es wird gezeigt, welche Regeln bei der Erstellung von technischen Freihandzeichnungen zu berücksichtigen sind (z.B. Linienstärke, Normschrift. . .).

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können die Elemente einer TZ benennen.
- Die Studierenden können begründen, warum dem Freihandzeichen auch im digitalen Zeitalter eine wichtige Rolle zukommt.
- Die Studierenden wissen, welche Materialien zur Erstellung einer Freihandzeichnung benötigt werden.
- Die Studierenden kennen die wichtigsten Zeichentechniken, z.B. zum freihändigen Zeichnen von Kreisen.
- Die Studierenden können einfache Freihandzeichnungen von einfachen Bauteilen erstellen.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden sind in der Lage, die Regeln für TZ anzuwenden und zu analysieren.
- Die Studierenden beherrschen die Normschrift freihändig und halten dabei die Randbedingungen, wie z. B. die Strichstärke und die Maße, ein.

- Die Studierenden können eine Bemaßung normgerecht skizzieren.
- Die Studierenden können einfache Bauteile in mehreren Ansichten projektionsgerecht freihändig zeichnen.

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können eine TZ überprüfen und kritisch bewerten. Sie sind in der Lage, komplexe Zeichnungen auszuarbeiten.
- Die Studierenden sind in der Lage, komplexe Einzelteil- und Baugruppenzeichnungen freihändig zu zeichnen.
- Die Studierenden sind in der Lage, Fertigungszeichnungen eigenständig zu erstellen.
- Die Studierenden können eigene Gestaltungsideen freihändig skizzieren.

### 5.3.3 Ansichten und Dreitafelprojektion

Das Thema Ansichten und Dreitafelprojektion behandelt die Hauptansichten (Vorderansicht, Draufsicht, Seitenansicht), Dreitafel-Projektion, Isometrie (x- und y-Achse werden  $30^\circ$  zur Waagerechten eingetragen, z-Achse senkrecht; Maßstab 1 : 1 : 1) sowie die Dimetrie von Bauteilen. Bei Letzterem wird die Abzisse um  $42^\circ$  und die Ordinate um  $7^\circ$  zur Waagerechten eingetragen. Die Applikatenachse bleibt senkrecht und der Maßstab beträgt  $\frac{1}{2} : 1 : 1$ . [Kü16]

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können einfache Bauteile in mehreren Ansichten projektionsgerecht freihändig zeichnen.
- Die Studierenden können die wichtigen Ansichten benennen.
- Die Studierenden wissen, was die Begriffe Isometrie und Dimetrie bedeuten und können diese erklären.
- Die Studierenden können den Begriff Schattenriss erklären und können diesen einzeichnen.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden sind in der Lage, komplexe Bauteile in allen Ansichten zu zeichnen.
- Die Studierenden können Ansichten von Baugruppenzeichnungen analysieren, um so Bauteile benennen zu können.
- Die Studierenden können Bauteile in isometrischer und dimetrischer Ansicht zeichnen.

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können die Ansichten komplexer Baugruppen lesen und zeichnen. Sie sind in der Lage, komplexe Zeichnungen auszuarbeiten.
- Die Studierenden sind in der Lage, die Ansichten komplexer Einzelteil- und Baugruppenzeichnungen zu bewerten.
- Die Studierenden sind in der Lage, Fertigungszeichnungen eigenständig in allen Ansichten zu erstellen.

### 5.3.4 Zielorientierte Bemaßung

Bei der zielorientierten Bemaßung werden die Aspekte der fertigungs-, funktions- und prüfungsgerechten Bemaßung behandelt. Dieses Thema erörtert, wie Maßangaben unter Berücksichtigung der genannten Aspekte einzutragen sind und wie die vereinfachte Bemaßung sich wiederholender Elemente funktioniert. Die Bemaßungsregeln nach entsprechenden Normen ist dabei einzuhalten. Beispielobjekte können hierbei Frästeile oder Wellen sein.

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können die Grundlagen der Bemaßung benennen und erklären.
- Die Studierenden können fertigungs-, funktions- und prüfungsgerechte Bemaßungen erkennen und beschreiben.
- Die Studierenden wissen welche wesentlichen Kriterien und Unterschiede von fertigungs-, funktions-, und prüfungsgerechter Bemaßung ausschlaggebend sind und können diese beschreiben.
- Die Studierenden können wesentliche zu berücksichtigende Kriterien einer fertigungsgerechten Bemaßung aufzählen und erklären.
- Die Studierenden können die Definition einer Maßbezugskante erklären und deren Position in einer TZ erkennen.
- Die Studierenden können die möglichen zu fertigenden Konturen von den Fertigungsverfahren (Drehen, Fräsen, Bohren) benennen und beschreiben.
- Die Studierenden können das benötigte Fertigungsverfahren anhand von dargestellten Bauteilen (in einer TZ) erkennen und beschreiben.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden sind in der Lage, Bemaßungsfehler in einer TZ zu erkennen und zu analysieren.

- Die Studierenden können einzelne Bemaßungen an einem Bauteil in fertigungs-, funktions- und prüfgerechte Bemaßung unterteilen.
- Die Studierenden sind in der Lage zu analysieren, ob Maßbezugsanten sinnvoll zur Fertigung eines Bauteiles gesetzt sind.
- Die Studierenden können die Position des Nullpunktes anhand von Maßbezugsanten bestimmen.
- Die Studierenden können mögliche Fertigungsmöglichkeiten zur Erstellung einer Bauteilgeometrie bestimmen und analysieren.
- Die Studierenden können einzelne Fertigungsschritte und die richtige Reihenfolge zur Erstellung eines Bauteiles beschreiben und analysieren.
- Die Studierenden können wesentliche Schritte (z.B. Einspannen des Bauteiles, Fräserposition etc.) zur Erstellung eines Bauteiles analysieren.

### III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können die geometrischen Dimensionen unter Berücksichtigung verschiedener Fertigungsverfahren fertigungsgerecht bemaßen.
- Die Studierenden sind in der Lage, unterschiedliche Bemaßungsmöglichkeiten unter Berücksichtigung von vorgegebenen Fertigungsverfahren zu bewerten und auszuarbeiten.
- Die Studierenden sind in der Lage, eine TZ (mit fertigungs-, funktions- und prüfgerechter Bemaßungen) zu analysieren und zu bewerten.
- Die Studierenden können TZ (auch unter Berücksichtigung der Fertigungsverfahren) analysieren, überprüfen und bewerten.
- Die Studierenden können den Rechen- und Arbeitsaufwand zur Erstellung von Bauteilen in einer TZ unter Berücksichtigung des Fertigungsverfahrens beurteilen.

### 5.3.5 Schnitte und Zeichnungsgruppen

Im Thema Schnitte und Zeichnungsgruppen wird gezeigt, wie Positionsnummern, Zeichnungsnummern, Stücklisten und Schriftfelder in einer TZ einzutragen sind und wie mit mehreren zusammenhängenden Zeichnungen (Zeichnungsgruppen) umgegangen wird. Es wird diskutiert, welche Bauteile wie zu schneiden sind bzw. welche Möglichkeiten es gibt, diese geschnitten darzustellen (Schnitt bzw. Vollschnitt, Halbschnitt, Teilschnitt bzw. Ausbruch). Darüber hinaus werden die Regeln zu verdeckten Kanten und wann Teile geschnitten werden dürfen abgehandelt.

### I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können Teil-, Halb- und Vollschnitte unterscheiden und benennen.
- Die Studierenden können einzelne Bauteile in Zusammenbauzeichnungen identifizieren.
- Die Studierenden können die Möglichkeiten zum Beschriften von Zusammenbauzeichnungen aufzählen.
- Die Studierenden können anhand von Positionsnummern Bauteile einer Stückliste mit der entsprechenden Zusammenbauzeichnung in Verbindung bringen (zuordnen).
- Die Studierenden können die Regeln zum Anbringen von Positionsnummern benennen.
- Die Studierenden können den Aufbau von Stücklisten erklären.

### II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden sind in der Lage, Teil-, Halb- und Vollschnitte von einzuzeichnenden Bauteilen normgerecht anzuwenden.
- Die Studierenden können einzelne Bauteile in Zusammenbauzeichnungen analysieren.
- Die Studierenden können Stücklisten lesen und erstellen.

### III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können normgerechte Schnittdarstellungen für Bauteile und Baugruppen erstellen und bewerten.
- Die Studierenden sind in der Lage, die Funktion einer Baugruppe aus der Zusammenbauzeichnung abzuleiten.
- Die Studierenden können Zusammenbauzeichnungen erstellen und den Zusammenhang verschiedener Zeichnungen herstellen.

## 5.3.6 Normung und GPS (Geometrische Produktspezifikation)

Das Themengebiet Normung und GPS beinhaltet zum einen die Normung, welche die Standardisierung von Bauteilen zum einfachen Austausch vorsieht, und zum anderen das GPS-System, welches der Beschreibung technischer Bauteile auf der Grundlage der Funktion in der technischen Produktspezifikation, wozu auch die TZ zu zählen ist, dient, weil reale Bauteile nach der Fertigung Abweichungen von Ihrer Sollgeometrie

aufweisen. Außerdem werden die Begriffe und Methoden Tolerierungsprinzipien, geometrische Tolerierung, dimensionale Tolerierung, sowie die Toleranzanalyse diskutiert. Eine Toleranzanalyse erlaubt es, alle Bemaßungen und Toleranzen im Gesamtkontext bewerten zu können.

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können die Grundsätze des GPS-Normensystems nach DIN EN ISO 8015 aufzählen.
- Die Studierenden kennen sich mit dem grundlegenden Prinzip der Normung aus, sodass eine passende Norm zu einem Bauteil zugeordnet werden kann und vice versa.
- Die Studierenden können lineare Größenmaße und Abstandsmaße unterscheiden.
- Die Studierenden können zusätzliche Modifikatoren zur Veränderung und zur eindeutigen Beschreibung der Toleranzzone beschreiben.
- Die Studierenden können anhand von Positionsnummern Bauteile einer Stückliste mit der entsprechenden Zusammenbauzeichnung in Verbindung bringen (zuordnen).

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden kennen die verschiedenen Gestaltabweichungen und können diese im Kontext der Tolerierung berücksichtigen.
- Die Studierenden können eine Toleranzanalyse eigenständig durchführen.
- Die Studierenden können Normen im Kontext einer Baugruppe einordnen und analysieren.

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden sind in der Lage, Bauteile in TZ nach dem aktuellen Stand der Normen nach Vorgabe funktionsgerecht zu bemaßen und zu tolerieren.
- Die Studierenden sind in der Lage, eine Toleranzkettenanalyse zu evaluieren.
- Die Studierenden können Normen interdisziplinär beurteilen und ausarbeiten.

### **5.3.7 Toleranzen und Passungen**

Das Themengebiet Toleranzen und Passungen umfasst zunächst die Grundlagen der Toleranzen (Bedeutung, Nutzen, Bezug zur Fertigung) sowie die Schließmaß und Toleranzbestimmung. Es werden außerdem die Maßtoleranzen (ISO-Toleranzen und Passungen, Maßtoleranzangabe in TZ und Allgemeintoleranzen), sowie die Geometrietoleranzen

(Form- und Lagetoleranzen, Tolerierung von Lagersitzen und Lagerbaugrößen, Oberflächenangaben, Werkstückkanten) mit inbegriffen.

### I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden wissen, warum Toleranzen und Passungen im Maschinenbau notwendig sind (Fertigungsabweichungen).
- Die Studierenden können die verschiedenen Maß- und Geometrietoleranzen auflisten.
- Die Studierenden verstehen die Angabe von Toleranzen in TZ, indem Toleranzen in Zeichnungen gelesen und benannt werden können.
- Die Studierenden sind in der Lage, alle gängigen Messmöglichkeiten zur Bestimmung einer Abmessung zu benennen und können entscheiden, ob eine Toleranz erreicht wurde.
- Die Studierenden können alle Form- und Lagefehler aufzählen und diese erklären.
- Die Studierenden können den Begriff Allgemeintoleranzen erklären und erörtern, warum diese angewendet werden.
- Die Studierenden können das System-Einheitsbohrung beschreiben.
- Die Studierenden sind in der Lage, den Begriff Oberfläche im Kontext des Maschinenbaus technisch zu beschreiben.

### II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden können Toleranzen und Passungen anhand einer Welle anwenden und die gegenseitige Beeinflussung analysieren.
- Die Studierenden können am Beispiel einer Welle bei angegebenen Toleranzen und Passungen die Toleranzgrenzen ermitteln.
- Die Studierenden können eine Tolerierung an einzelnen Bauteilen anhand von Normtabellen vornehmen.
- Die Studierenden können beschreiben, wie Toleranz- und Passungssysteme bezüglich Oberflächenangaben sowie Form- und Lagetoleranzen geprüft und nachgemessen werden können (Verfahren).
- Die Studierenden können eine Toleranzkette mit Hilfe der Allgemeintoleranzen analysieren.
- Die Studierenden können eine ISO-Tolerierung auf Wellen und Bohrungen eigenständig anwenden.
- Die Studierenden können das System-Einheitsbohrung auslegen.

- Die Studierenden können Form- und Lagetoleranzen (auf einer Welle) anhand der vorhandenen Bemaßung bestimmen.
- Die Studierenden können Maßketten analysieren und auslegen (Maximum-Material Bedingung).

### III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können Toleranz- und Passungssysteme interdisziplinär in Verbindung zu Problemstellungen verschiedener thematischer Natur (Fertigung, Belastung, Konstruktion. . .) analysieren und diese Systeme auslegen.
- Die Studierenden sind in der Lage, Toleranz- und Passungssysteme zu evaluieren.
- Die Studierenden sind in der Lage, ein geeignetes Fertigungsverfahren bzw. Fertigungsbedingungen für Toleranz- und Passungssysteme auszuwählen und die Fertigung zu planen.
- Die Studierenden sind in der Lage, eine Schließmaß und Toleranzbestimmung eigenständig vorzunehmen und die Eignung für Anwendungsszenarien zu bewerten.
- Die Studierenden können Oberflächenangaben im Hinblick auf die Beanspruchung beurteilen.
- Die Studierenden können das Gesamtsystem im Hinblick auf weitere Problemstellungen wie Lebensdauer, Verschleiß und Korrosion bewerten.
- Die Studierenden können Passungssysteme (System-Einheitswelle) für spezielle Anwendungsfälle auswählen.

### **5.3.8 Normteile und Maschinenelemente (insbesondere Schraubenverbindungen)**

Das Themengebiet Normteile und Maschinenelemente beinhaltet die wichtigsten Normteile, die ein Ingenieur bzw. eine Ingenieurin im Maschinenbau kennen sollte. Dazu gehören Lager, Sicherungsring, Wellenmutter, Sicherungsblech, Passfeder, Radialwellendichtring, O-Ring, Zahnräder und Federn. Innerhalb dieses Themas der Normteile werden bspw. Aufbau und Funktion abgehandelt.

#### I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können die oben beschriebenen Norm- und Maschinenteile aufzählen.
- Die Studierenden können den Aufbau der Normteile beschreiben.
- Die Studierenden können die Darstellung der Normteile innerhalb einer TZ vornehmen und erklären.

- Die Studierenden können die grundlegenden Funktionen und Aufgaben gängig verwendeter Normteile benennen.
- Die Studierenden können die Komponenten von Schraubenverbindungen erkennen und benennen.
- Die Studierenden können die verschiedenen Arten von Schrauben und Schraubenverbindungen erkennen und benennen.
- Die Studierenden können die Elemente einer Schraubenverbindung benennen und verstehen die Herstellung grundlegend, indem sie die Fertigungsschritte beschreiben können.

### II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden können Normteile innerhalb einer TZ analysieren, indem sie bspw. die Funktion des Normteils innerhalb einer Baugruppe beschreiben können.
- Die Studierenden können Normteile, wie z.B. Lager, aus einer Norm entnehmen und z.B. auf eine Welle einzeichnen.
- Die Studierenden können eine geeignete Auswahl von Normteilen für eine vorgegebene Problemstellung treffen.
- Die Studierenden können die grundlegenden Funktionen und Aufgaben gängig verwendeter Normteile benennen.
- Die Studierenden können die Komponenten von Schraubenverbindungen erkennen und benennen.
- Die Studierenden können eine Schraubenverbindung auswählen und die Eignung der Verbindung aus Sicht der technischen Anforderungen analysieren (z.B. Festigkeitsklasse).
- Die Studierenden sind in der Lage, Kraftverläufe und Kraftflüsse auf einer Welle (insbesondere im Hinblick auf Lagerbauarten) einzuzeichnen (analysieren).
- Die Studierenden können Zahnradgrößen zuordnen und deren Bedeutung, Verzahnungsarten und deren Anwendung und Darstellung in einer TZ analysieren und dies anschaulich darlegen.
- Die Studierenden können unterschiedliche Schraubenverbindungen und Schraubentypen fehlerfrei einzeichnen.
- Die Studierenden sind in der Lage, geeignete Komponenten einer Schraubenverbindung aufgrund geometrischer Gegebenheiten auszuwählen.

### III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können die Auswahl und Anordnung von Normteilen in einer Maschine überprüfen und ggf. Optimierungen im Hinblick auf externe Einflüsse vornehmen.
- Die Studierenden können die Auswahl der Normteile im Hinblick auf die Anforderungen bewerten.
- Die Studierenden sind in der Lage, Norm- und Maschinenteilesysteme zu evaluieren. In diesem Zusammenhang können sie Kraftverläufe und Belastungsarten interdisziplinär bewerten (z. B. ob die Toleranz mit der Funktionalität einhergeht bzw. das Passungssystem bewerten).
- Die Studierenden können bewerten, ob eine Welle für das jeweilige Normteil geeignet ist bzw. die Funktionalität gegeben ist.
- Die Studierenden können die fertigungsgerechte Bemaßung der Norm- und Maschinenteile sowie die dazugehörigen umliegenden Bauteile in dem Wirksystem (z. B. Montageschräge für den Radialwellendichtring) gestalten.
- Die Studierenden können Normteile nach Anforderungen auswählen (Bspw. Lager; Auswahl Sicherungselement für hohe Axialkräfte) und in einer TZ ausarbeiten.
- Die Studierenden sind in der Lage, Schraubenverbindungen in Bezug auf interdisziplinäre Problemstellungen, wie Beanspruchung oder Verschleiß, bei einer Auslegung mit einzubeziehen und die Vor- und Nachteile des Systems herauszustellen.

### 5.3.9 Wellenbearbeitung

Bei der Wellenbearbeitung reichen die Inhalte von Fertigungsverfahren, über Fertigungsschritte zum Herstellen einer Welle bis hin zum Erarbeiten einer Fertigungsbeschreibung für die Fertigung.

#### I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können die grundlegenden Fertigungsverfahren zum Herstellen einer Welle (urformende, umformende und spanende Fertigungsverfahren) benennen und beschreiben, wie diese funktionieren. Darüber hinaus können die Werkzeuge, die für die Herstellung verwendet werden, aufgezählt werden.
- Die Studierenden können den Aufbau einer Welle beschreiben und die wesentlichen Elemente benennen.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden können die Bearbeitungsschritte einer Welle insofern analysieren, als dass sie eine Fertigungsbeschreibung selbstständig erstellen können.
- Die Studierenden können die Komponenten einer Welle (Absätze, Freistich. . .) analysieren, indem sie mit den verwendeten Normteilen in Verbindung gebracht werden.
- Die Studierenden können die Arbeitsschritte zur Fertigung einer Welle analysieren und wiedergeben.

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können die Wellenbearbeitung unter Vorlage einer TZ planen und für die Fertigung normgerecht darlegen.
- Die Studierenden können die Wellenbearbeitung besonders im Hinblick auf Toleranz- und Passungssysteme bewerten und sind in der Lage, die Bearbeitung an die geforderten Passungssysteme auszulegen.

### **5.3.10 Lesen und Interpretieren Technischer Zeichnungen**

Beim Lesen von TZ, speziell Einzelteilzeichnungen und Baugruppenzeichnungen spielt das räumliche Vorstellungsvermögen eine wichtige Rolle. Es geht darum, dass die Zusammenstellung und Funktion ganzer Maschinen erkannt und beschrieben werden kann, damit eine Analyse stattfinden kann. Die Kompetenzen zu den vorherigen Themengebieten sollten auf dem jeweiligen Niveau ausgebaut sein, weil es auf den anderen Themen aufbaut. Für die Benennung der Funktion einer Maschine ist es bspw. notwendig, dass Studierende wichtige Normteile kennen und diese identifizieren können.

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können beschreiben, welche Ansichten zu sehen sind und die vorliegende Zeichnung einordnen.
- Die Studierenden können in TZ (auch Baugruppenzeichnungen) den Aufbau der Zeichnung erläutern.
- Die Studierenden können die Elemente bzw. Bauteile in einer TZ benennen, d.h. Bauteilgeometrien ermitteln.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden können eine Maschine analysieren, indem die Funktion einer Baugruppe sowie der einzelnen Bauteile beschrieben werden kann, und so auf die Gesamtfunktion schließen.

- Die Studierenden können auftretende Kräfte wahrnehmen und einfache Kräftegleichgewichte aufstellen (analysieren).

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden können Maschinen und komplexe Baugruppen evaluieren.
- Die Studierenden erkennen Fehler in TZ (evaluieren).
- Die Studierenden können technische Systeme hinsichtlich ihrer Funktion bewerten, d. h. Fehler erkennen und diese selbstständig beheben.

### 5.3.11 Einführung in CAD

Beim CAD (Computer Aided Design) geht es um die Digitalisierung technischer Zeichnungen. Das CAD-System bietet den Vorteil, dass räumliche Modelle virtuell abgebildet werden können. Einige Aufgaben, wie die Erstellung von Stücklisten, können automatisiert werden.

I. Geringer fachlicher Anspruch – Einfaches Niveau:

- Die Studierenden können beschreiben, was ein CAD-System ist und wofür dieses verwendet wird.
- Die Studierenden können die Vorteile von CAD-Systemen benennen.
- Die Studierenden können CAD-Austauschformate benennen.
- Die Studierenden können wiedergeben, wie die CAD-Modelle in weiteren CAE-Modulen genutzt werden.
- Die Studierenden kennen den Nutzen von CAD-Systemen im Kontext des Datenmanagements in Unternehmen und können dies erklären.

II. Mittlerer fachlicher Anspruch – Mittleres Niveau:

- Die Studierenden sind in der Lage, eine TZ in einem CAD-System zu analysieren.
- Die Studierenden können eine Zeichnung in ein CAD-System übertragen.
- Die Studierenden können digital skizzieren.
- Die Studierenden können die zu verarbeitenden Daten innerhalb eines CAD-Systems analysieren.

III. Hoher fachlicher Anspruch – Hohes Niveau:

- Die Studierenden sind sicher im Umgang mit CAD-Systemen. Dies kann anhand einer fehlerfreien und schnellen Übertragung einer vorliegenden TZ in CAD geprüft werden. Die Einarbeitungszeit in unbekannte CAD-Software ist schnell machbar und bereitet nur wenig Aufwand.

- Die Studierenden können in einem CAD-System selbstständig konstruieren, während eine kritische Hinterfragung stattfindet, sodass das geschaffene Bauteil optimiert werden kann.
- Die Studierenden können die Verknüpfung von Fertigungsverfahren wie z.B. Rapid Prototyping analysieren und erschaffen.
- Die Studierenden können die finalen Schritte zur Zeichnungserstellung digital in CAD einleiten (ausarbeiten) und darüber hinaus weitere Komponentensysteme zur Evaluation nutzen (z. B. mechanische Simulation und Inventor Studio).

### 5.4 Zusammenfassung der Anforderungen und Synthese

Dieses Unterkapitel befasst sich mit der Vereinbarkeit der Anforderungen. Aus der Evaluation geht hervor, dass fast alle Teilnehmenden der Meinung sind, dass die eingesetzten Medien gut handzuhaben sind und zum Erreichen der Lehr-/Lernziele beitragen. Außerdem ist die Akzeptanz einiger Themen aufgrund der transparenten Lernziele gestiegen (siehe Evaluationsergebnisse), weil diese am Anfang des Lernmaterials veranschaulicht werden. Das bedeutet, dass die Umsetzung des *Constructive Alignment* zur Bewältigung der in der ersten Umfrage festgestellten Probleme funktioniert. Die verschiedenen Sichtweisen der Studierenden und Lehrenden laufen zusammen. Die Studierenden verstehen besonders mit Blick auf das Thema Freihandzeichnungen, warum bestimmte Fähigkeiten nicht nur für zukünftige Themen an der Hochschule, sondern auch für die spätere berufliche Tätigkeit wichtig sind. Daraus wird abgeleitet, dass **das *Constructive Alignment* für die Definition der Kompetenzniveaus verwendet und die Lernziele sichtbar im Material eingebaut werden sollten.**

Andererseits funktioniert die freiwillige Nutzung von OER-Materialien nicht wie von den Lehrenden gewünscht, da laut der abschließenden Evaluierung nur wenige Studierende die OER-Lernmaterialien nutzen. Die Verfolgung der Aktivitäten zeigt, dass viele Studierende den Test zur Überprüfung des Taxonomieniveaus durchgeführt haben. Es scheint, dass die Studierenden, die das Material genutzt haben, nicht an der Umfrage teilgenommen haben und umgekehrt. An diesem Punkt lässt sich erkennen, dass bei den freiwilligen Umfragen nicht der gewünschte Umfang an Teilnehmenden erreicht wird. Es sind verstärkende Faktoren erforderlich, um die Beteiligung zu erhöhen. **Wenn das Lernmaterial in eine Veranstaltung fest integriert wird, ist davon auszugehen, dass die Beteiligung der Studierenden an der Evaluation und die Anzahl der Studierenden, die das OER-Lernmaterial nutzen, steigen wird.**

Wie und welche Metadaten anzugeben sind, wird in diesem Kapitel ausführlich erläutert. Es wird bei der Bereitstellung von OER-Portalen verpflichtend gefordert, damit

eine Veröffentlichung stattfinden kann. Daher ist die **Angabe eines vollständigen Metadatenprofils inklusive der Nennung aller Autor\*innen und Lizenzen unbedingt notwendig**.

Im Allgemeinen ist es von Vorteil, die MOOC/OER-Lernmaterialien mit vielen Partner\*innen zu erstellen, da so unterschiedliche Perspektiven und Erfahrungen einfließen können. Alle Themen werden abgedeckt und die Arbeit kann entsprechend der jeweiligen Expertise aufgeteilt werden. Die Aufteilung der Arbeit hilft, die gesamte Themenlandschaft abzudecken, so dass das Angebot vollständig ist und sich alle Lehrenden selbst bedienen können. Die Bildung von Arbeitsgruppen hilft bei der effektiven Bearbeitung und Erstellung der Lernmaterialien. Die Partner\*innen können einen Überarbeitungsprozess des Lernmaterials einleiten, so dass die Qualität gesichert ist. **Es ist sinnvoll Synergien zu schaffen und OER-Materialien gemeinsam innerhalb von Kooperationen zu entwickeln.** [Dil23b; DK22] Außerdem bieten sich folgende Punkte für die Erstellung von OER-Materialien an, die als Grundlagenfach im Studium behandelt werden [Dil23c]:

- möglichst nicht auf Vorwissen (inhaltlich und methodisch) setzen,
- Fachvokabular gezielt einführen und erläutern (ggf. gemeinsames Glossar im Projekt),
- deutliche (plakative) Strukturierung der Inhalte,
- detaillierte (methodische) Anleitung insbesondere bei interaktiven Elementen,
- standardisiertes (und automatisiertes) Feedback für Aktivitäten über LMS einplanen, um den Betreuungsaufwand zu reduzieren,
- Skalierbarkeit einplanen,
- Bausteine auch innerhalb einzelner Themen zur Gewährleistung der Modularität,
- größere Sammlung an Aufgaben und Beispielen (auf unterschiedlichen Niveaus),
- asynchrone Kommunikationswege stärker berücksichtigen (Foren, FAQs, Feedback etc.),
- peer-to-peer Austausch (z.B. in Foren) stärken.

Die in diesem Kapitel definierten Lernzieltaxonomien besitzen durch die Einbeziehung der verschiedenen Anforderungen einen allgemeingültigen Charakter. Für die Definitionen wurden Evaluationen durchgeführt und Daten werden analysiert. Mit diesem Bewertungsgerüst kann die Fähigkeit der KI im weiteren Verlauf evaluiert werden.

# 6 Integration der KI-Objekterkennung in die Lehre

Es wird ein computergestütztes Unterstützungstool für angehende Ingenieure bzw. Ingenieurinnen entwickelt, das in **Abbildung 6.1** zu sehen ist. Dieses Tool soll einen potenziellen Anwendungsfall für die KI-Detektion aufzeigen. Die Lernsoftware mit Objektdetektion wird für das Modul Technisches Zeichnen im Bachelor entwickelt, damit die KI für die Lehre zukünftiger Ingenieure bzw. Ingenieurinnen genutzt werden kann. Anhand dessen können die später durchgeführte Analyse und Bewertung des Niveaus der KI erbracht werden. Diese Anwendung stellt die softwaretechnische Grundlage für Aufgabenstellungen innerhalb der Lehrveranstaltung dar. Aus dieser Anwendung können verschiedene Aufgabenstellungen erarbeitet werden, die für unterschiedliche Kontexte genutzt werden können.

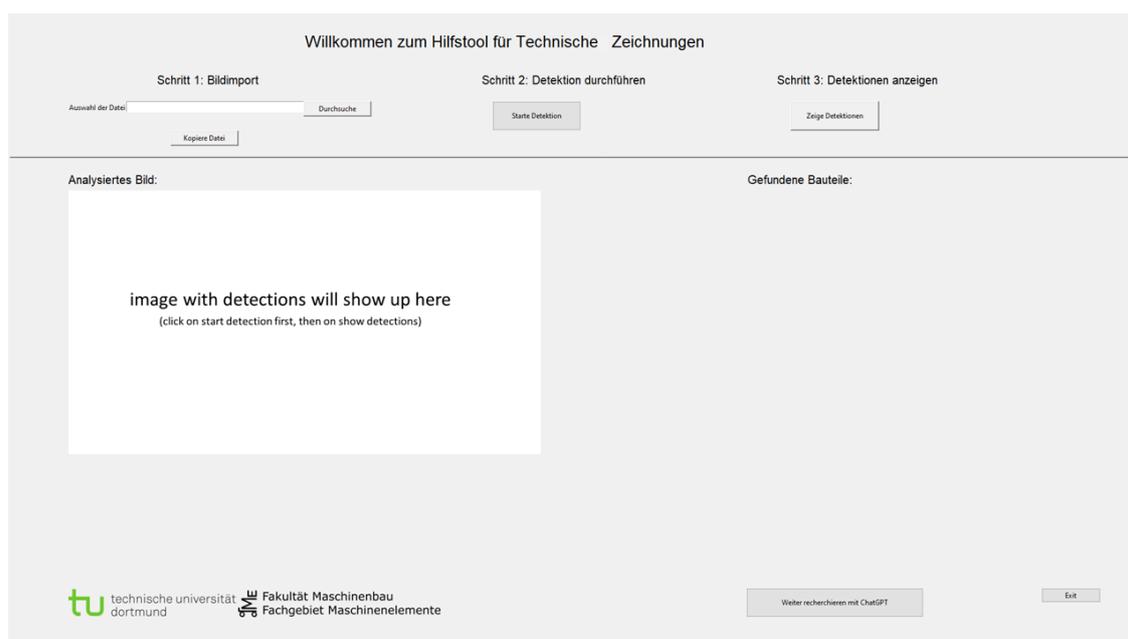


Abbildung 6.1: Übersicht über das entwickelte Unterstützungstool für Studierende

## 6.1 Beschreibung des Objekterkennungsprogramms

Die Software soll als Lernprogramm für die Nutzenden so leicht wie möglich aufgebaut sein. Deshalb wird der gesamte Inhalt auf einer Seite innerhalb der Benutzeroberfläche dargestellt. Die Lernaktivität gliedert sich in drei Schritte, welche von links nach rechts chronologisch aufgelistet sind. Die Software wird mit *Python* programmiert.

Der Programmcode ist in Anhang B beigefügt. Für die Benutzeroberfläche wird die Bibliothek *tkinter* genutzt. Zur Darstellung von *ChatGPT* innerhalb eines Fensters wird *webview* verwendet.

### Schritt 1: Bildimport

Wenn Studierende auf Probleme stoßen, Bauteile innerhalb einer TZ identifizieren zu können, können diese Bilder abfotografiert oder als Datei in die Software geladen werden. Dies geschieht über den Bildimport oben links auf der Benutzeroberfläche. Wenn es feste Aufgabenstellungen mit schon vorhandenen TZ gibt, kann dieser Schritt aus der Chronologie entfernt werden. Für das vorliegende Beispiel soll die gewünschte zu analysierende Datei über die „browse“-Schaltfläche aus dem Dateixplorer ausgewählt werden, welcher beim Drücken des Knopfes erscheint. Nachdem eine Datei ausgewählt wurde, erscheint der Pfad in dem weiß hinterlegten Feld links neben der „Durchsuche“-Schaltfläche (siehe **Abbildung 6.2**). Daraufhin wird die ausgewählte Datei über den Schaltknopf „Kopiere Datei“ in den KI-Ordner kopiert, damit die Detektion die Datei aus einem vorher definierten Ordner entnehmen kann. Die KI-Detektion ist in der Lage, mehrere Bilder gleichzeitig zu analysieren. Dies kann durch eine mehrseitige Bildvorschau in der Anwendung implementiert werden. Allerdings macht es aus didaktischer Sicht keinen Sinn, sich bei Problemen mit der Analyse technischer Zeichnungen gleichzeitig alle auf einmal anzusehen. Die Bearbeitung und damit auch die Detektion in hintereinander befindlicher Reihenfolge, damit ein Bild in Ruhe analysiert werden kann, ist für den Lernfortschritt zweckdienlich.

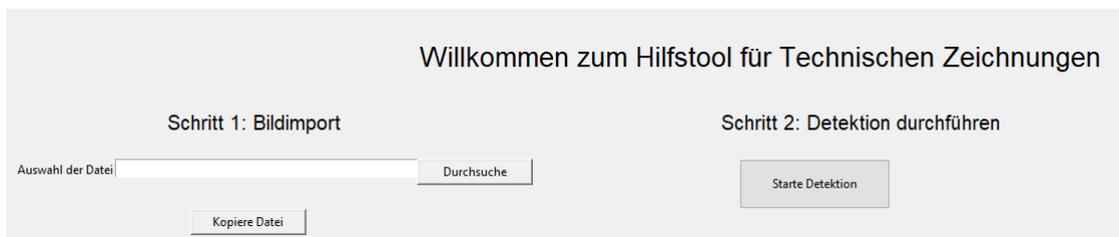


Abbildung 6.2: Bildimport und Starten der KI-Detektion

### Schritt 2: Detektion

Im Schritt der Detektion wird der KI-Detektor angestoßen. Über die Schaltfläche „Starte Detektion“, welche in Abbildung 6.2 dargestellt ist, wird die KI-Detektion über eine Batch-Datei gestartet. Eine Batch-Datei ist eine Windows-Befehlsdatei mit mehreren Kommandozeilen innerhalb einer Text-Datei. Die in Anhang A befindliche Batch-Datei beinhaltet die folgenden Befehle. Zunächst werden die Pfade der *Anaconda* Installation und der Umgebungsname festgelegt. *Anaconda* ist eine auf der Programmiersprache *Python* basierende Entwicklungs- und Programmierumgebung, welche bspw. die KI-Detektion mittels *YOLO* ausführen kann. Nachdem *Anaconda* in Zeile 13 gestartet wurde, beginnt der eigentliche Detektionsschritt.

Der in dem das KI-Modell befindliche Pfad wird zunächst angegeben, damit die Umgebungsdatei (.yaml) identifiziert werden kann, in der alle Modellabhängigkeiten gespeichert sind. Hier sind zum Beispiel die Versionen von *Tensorflow* und *pytorch* hinterlegt, welche durch die KI-Detektion genutzt werden. Die beiden zuletzt genannten Programme werden verwendet, um die Berechnung, wie zum Beispiel Rechenoperationen mit Tensoren, der KI vollziehen zu können. In Zeile 17 wird der eigentliche Detektionsbefehl ausgeführt. Hier werden die Parameter Bildgröße (Auflösung), Vertrauenswert und IoU-Schwelle definiert. Die IoU-Schwelle ist in dieser Zeile nicht angegeben und wird standardmäßig auf den Wert 0,5 gesetzt. Außerdem wird die für die Berechnung verwendete Hardware angegeben. Bei „Device 0“ handelt es sich hier um die Grafikeinheit. Außerdem werden die Gewichtungen (weights) aus dem Training angegeben. Am Ende der Batch-Datei wird die Umgebung deaktiviert. Nach der Detektion wird das Bild in einen Ausgabeordner abgespeichert. Die Angabe in der Befehlszeile der Detektion „-save-txt“ besagt, dass eine Text-Datei mit den Detektionsinformationen ebenfalls im Ausgabeordner abgelegt wird. Das Schema der Textausgabe folgt der in Abschnitt 4.1.1 gezeigten Konvention.

### Schritt 3: Anzeigen der Detektionen

Bei Klick auf „Zeige Detektionen“ wird das analysierte Bild aus dem Ausgabeordner in der Oberfläche links angezeigt (siehe **Abbildung 6.3**). Für dieses Beispiel wird ein Bild aus dem Vorlesungsskript, welches aus dem Buch *Maschinenelemente kompakt* [Kün19] stammt, verwendet. Das Bild zeigt eine Welle mit aufgesetztem Ritzel, dessen Zähne durch den KI-Detektor erkannt werden. Außerdem wird die Passfederverbindung zur Drehmomentübertragung sowohl unter dem Zahnrad als auch am Wellenende ebenfalls markiert.

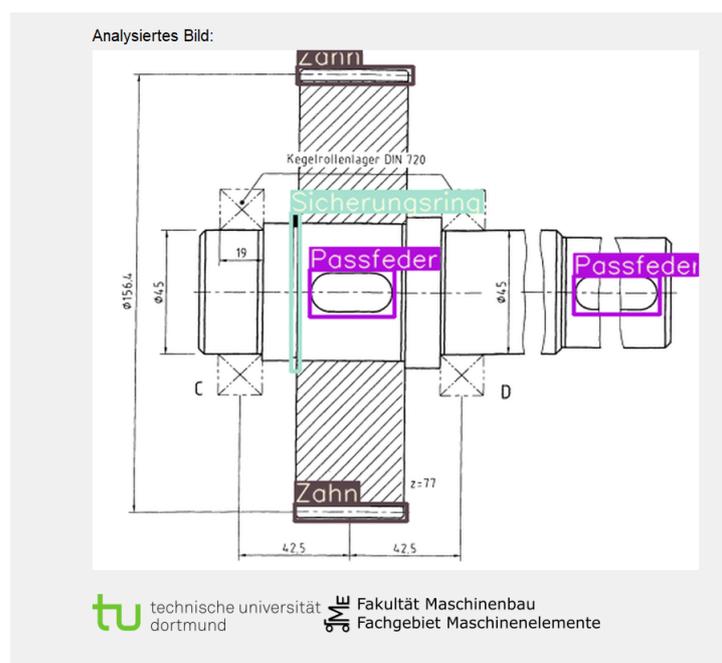


Abbildung 6.3: Angezeigte Detektion im Bild (detektiertes Bild aus [KW19])

Vervollständigt werden die Detektionen durch das Auffinden des Sicherungsringes zur axialen Fixierung des Zahnrades. Es handelt sich um ein Bild, welches sich von den Trainingsdaten deutlich unterscheidet. Trotzdem werden alle darin befindlichen Bauteile gefunden, welche sich in der Definition der Klassen wiederfinden.

Auf der rechten Seite ist ein Listenmenü angeordnet, welches in **Abbildung 6.4** dargestellt ist. In dieser Liste werden alle gefundenen Bauteile aufgelistet, nachdem die Schaltfläche „Zeige Detektionen“ betätigt wird. Über das Auslesen der Text-Datei im Ausgabeordner der KI-Detektion können die detektierten Bauteile ausgegeben werden. Wenn ein Eintrag der Liste ausgewählt wird, erscheint in einem Textfeld unter der Liste der besagte Bauteilname. Darunter wird ein Text mit Erklärungen bereitgestellt, um dem Betrachter den Aufbau und die Funktion des Bauteils näher zu bringen. Außerdem ist in Abbildung 6.4 zu sehen, dass neben dem Erklärungstext die Quelle für diese Angaben angegeben ist, aus der weitere Informationen entnommen werden können.

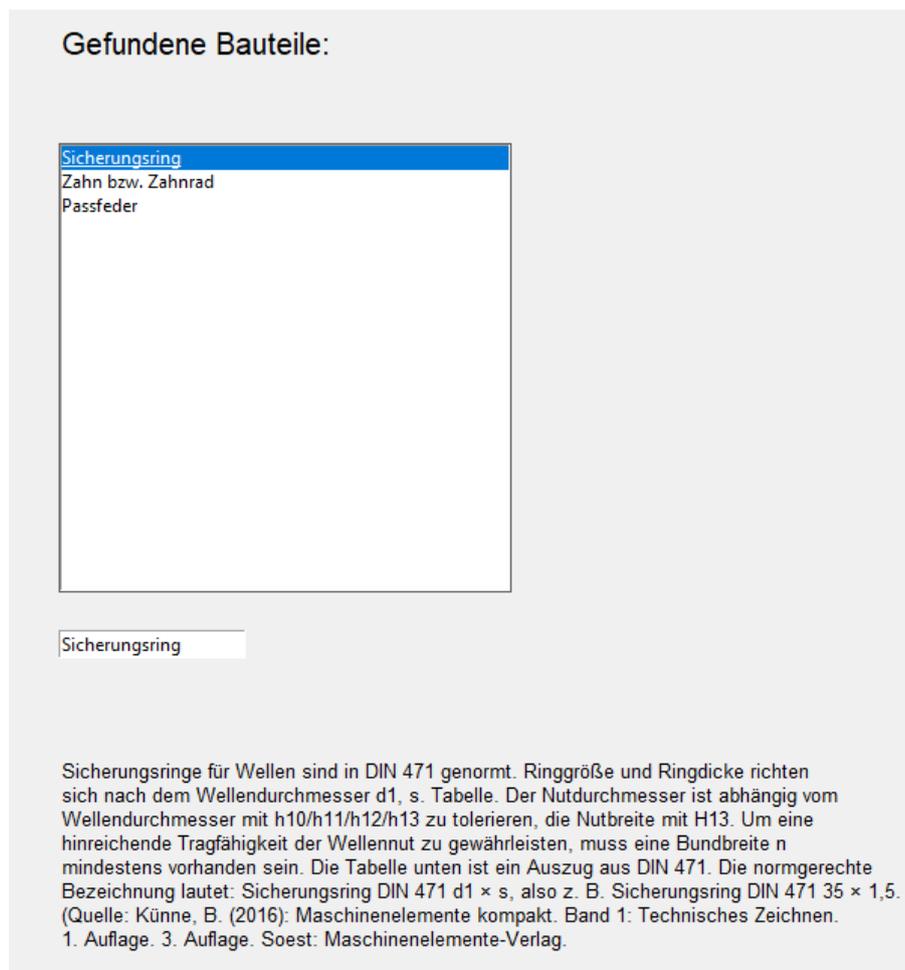


Abbildung 6.4: Dropdown Menü mit Erklärungen zum gefundenen Bauteil

Beim Betätigen der Schaltfläche „Weiterrecherchieren mit ChatGPT“ öffnet sich ein Fenster, in dem *ChatGPT* gestartet wird. Es wurde ursprünglich versucht, den Chat mit

*ChatGPT* direkt in die Benutzeroberfläche einzubinden, ohne dass sich die Studierenden einloggen müssen. Dafür wird ein API-Key (Application Programming Interfaces oder Programmierschnittstellen) bezogen und in die Programmierung mit eingebaut. Mit diesem Key ist es möglich, dass die Software Daten mit *ChatGPT* austauscht. Anfangs hat es funktioniert, jedoch werden nach einer gewissen Anzahl an Abfragen die Kommunikationswege durch *OpenAI* geblockt. Ab einer gewissen Kommunikationsmenge müssen kommerzielle Modelle abonniert werden, damit die Kommunikation aufrechterhalten bleibt. Dies ist für die Verwendung als OER ungeeignet und nicht zielführend. Es ist zum jetzigen Stand nicht möglich, diese Unterstützung kostenfrei in die Unterstützungssoftware mit einzubauen. Daher muss sich der Nutzer in diesem Fenster mit seinen Kontodaten einloggen (siehe **Abbildung 6.5**). Das Erstellen eines Kontos ist kostenlos. Nachdem dies vollzogen wurde, kann *ChatGPT* mit seinen Funktionen genutzt werden, um sich über weitere Aspekte zu informieren. Das Fenster kann jederzeit geschlossen werden und neue Detektionen ausgeführt werden.

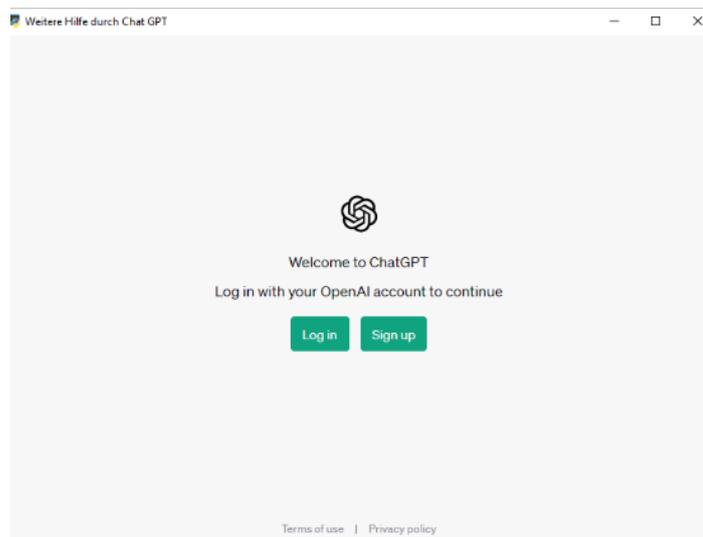


Abbildung 6.5: Weiter recherchieren mit *ChatGPT*

Die vorliegende Software ist zurzeit nur auf einem PC ausführbar, jedoch ist es möglich, dies browserbasiert über eine Website anbieten zu können. Dafür müsste die Benutzeroberfläche in eine Website integriert werden. Wenn die Umgebungen für die KI-Detektion auf dem Server installiert sind, kann eine Detektion über die vorhandene Batch-Datei gestartet werden. Da viele Server nicht auf eine Grafikkarte zurückgreifen, müsste die Berechnung über den Prozessor ausgeführt werden. Dies würde erheblich mehr Zeit in Anspruch nehmen, ist bei der Analyse eines Bildes als verkraftbar zu bewerten, weil die reine Detektionszeit von etwa 0,2 Sekunden auf mehrere Sekunden ansteigen wird. Generell ist die Integration auf einem Linux-basierten Server ebenfalls möglich, weil *YOLO* dieses Betriebssystem unterstützt.

## 6.2 Diskussion zur Integration in die Lehre

In diesem Unterkapitel werden potentielle Einsatzszenarien für das im zuvor vorgestellten Unterkapitel präsentierte Softwaretool aufgezeigt. Zunächst wird dies in Bezug die Lehrveranstaltung Technisches Zeichnen diskutiert. Anschließend wird analysiert, wie diese Grundbasis für weitere Anwendungen genutzt werden kann.

### 6.2.1 Unterstützungsfähigkeit bezüglich der im Technischen Zeichnen gelehrt Themen

Eine beispielhafte Übungsaufgabe des Technischen Zeichnens ist in **Abbildung 6.6** dargestellt. In dieser Aufgabe geht es um das Lesen und Verstehen einer TZ. Die Studierenden sollen in dieser Aufgabe die Funktion der Maschine, ein Winkelgetriebe, erläutern. Das Getriebe nimmt auf der Antriebswelle ein Drehmoment über eine Passfeder auf und leitet es über ein Kegelzahnrad an die Abtriebswelle weiter und gibt es über eine Passfederverbindung wieder ab. Sämtliche Kräfte werden über die Lager übertragen, welche außerdem die Rotation der Wellen erlauben. Auf der Antriebswelle sind Kegelrollenlager in einer Trag-Stütz-Lagerung bzw. O-Anordnung verbaut. Auf der Abtriebswelle werden Schrägkugellager in einer O-Anordnung verwendet. Zum Zwecke der Abdichtung sind RWDR verbaut. Über Öleinlass- und Ölablassschrauben an der linken und der unteren Seite des Gehäuses kann das Getriebeöl eingefüllt bzw. abgelassen werden. Das Gehäuse wird über vier Aufstandsfüße an die anliegende tragende Konstruktion verschraubt. Es handelt sich hierbei um ein Schweißgehäuse.

Erläutern Sie die Funktion der dargestellten Maschine bzw. Vorrichtung.

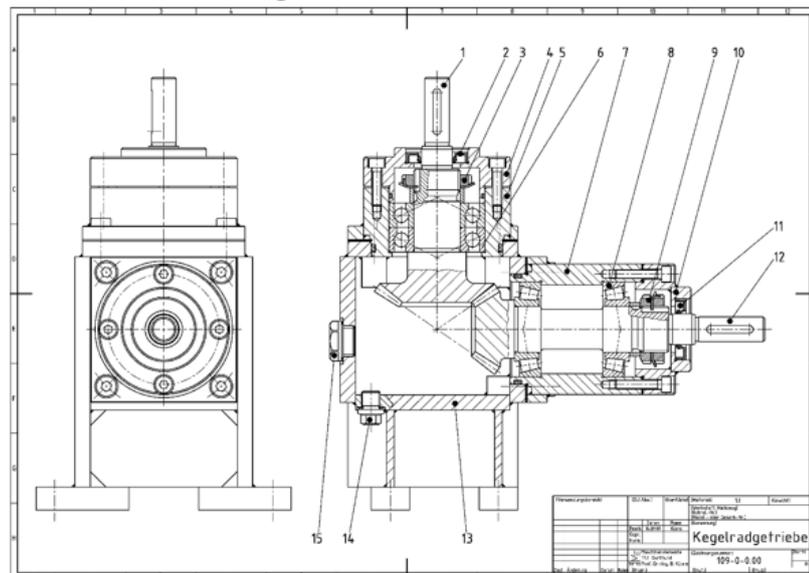


Abbildung 6.6: Beispielhafte Übungsaufgabe aus dem Modul Technisches Zeichnen

Der erste Schritt der Aufgabe beinhaltet die Erkennung der vorhandenen Bauteile. Dazu ist die KI-Detektion teilweise in der Lage, wie anhand der **Abbildung 6.7** und **Abbildung 6.8** zu erkennen ist. Die Erkennung wird nur teilweise vollzogen, weil nur die angelernten Klassen erkannt werden können. Die übrigen Bauteile werden nicht erkannt. Es ist möglich, den Detektionsbaukasten zu erweitern, damit die anderen Objekte in der Zeichnung ebenfalls identifiziert werden. Aufgrund der geringen Bildgröße sind hier falsche Detektionen vorhanden. Die gesamte Getriebezeichnung besitzt eine Bildgröße von 854x609 Pixel. Somit besitzen die manuell zugeschnittenen Bilder einer Bildgröße von etwa 500x300 Pixel. Dadurch können in Abbildung 6.7 Wellenmuttern nicht von Wellenmuttern mit Sicherungsblech unterschieden werden.

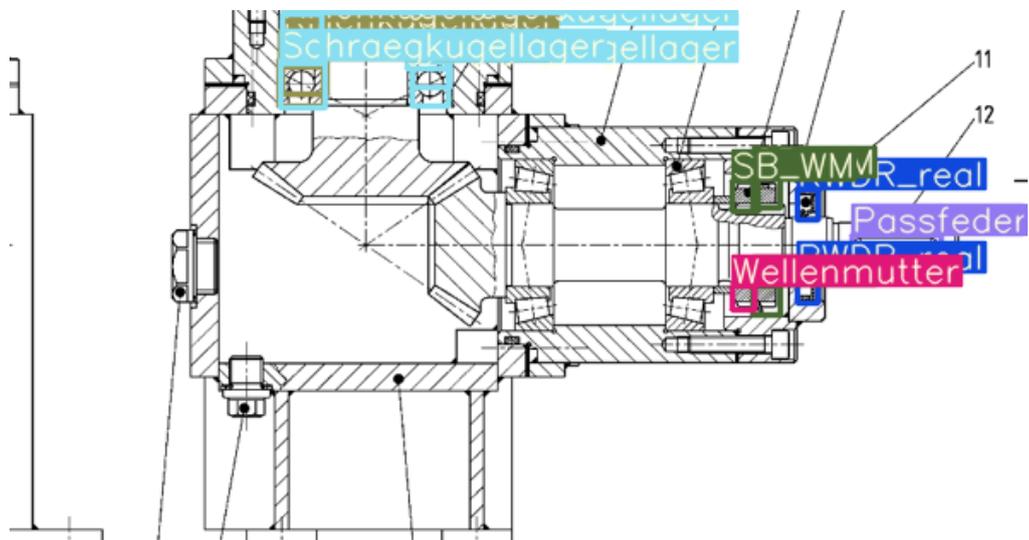


Abbildung 6.7: Detektionen an der Abtriebswelle zur Übungsaufgabe (Getriebe aus [Kü16])

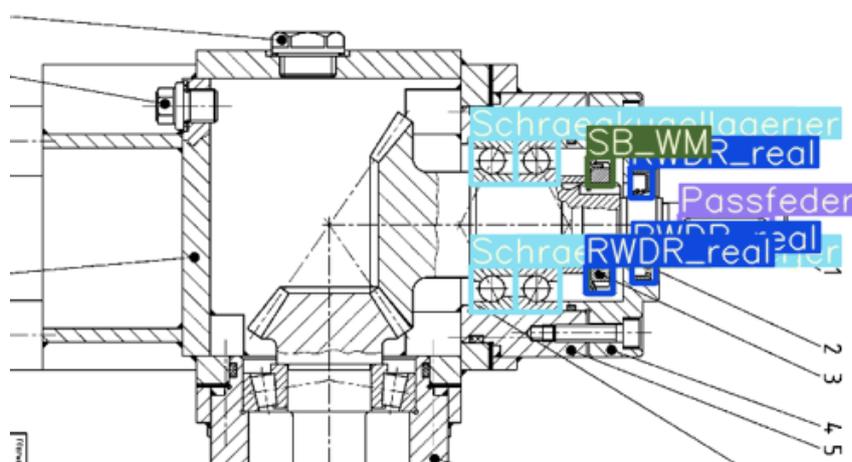


Abbildung 6.8: Detektionen an der Antriebswelle zur Übungsaufgabe (Getriebe aus [Kü16])

Die Abbildung 6.8 ist noch etwas niedriger aufgelöst, woraus sich eine falsch positive Detektion der Klasse RWDR\_real ergibt, obwohl an dieser Stelle eine Wellenmutter

mit Sicherungsblech vorhanden ist. Außerdem wird die Sicherungsblechnut nicht erkannt, weil diese in der vorliegenden Darstellung nicht angelernt wurde. Damit sind Limitationen der KI-Detektion festzuhalten, da schlechter aufgelöste Zeichnungen nicht die Zuverlässigkeit garantieren, die in der obigen Analyse gegeben ist. Außerdem ist es fraglich, ob sehr individuelle Geometrien von Bauteilen, wie zum Beispiel Gehäuse, durch die KI-Detektion anlernbar und zuverlässig detektierbar sind. Nachdem die Bauteile erkannt wurden, kann *ChatGPT* zu Hilfe genommen werden, um die Funktion der Bauteile zu analysieren.

Es folgt eine Antwort von *ChatGPT*, wenn man in den Chat Passfeder eingibt:

*„Eine Passfeder ist ein mechanisches Bauteil, das zur Verbindung von zwei oder mehreren Bauteilen verwendet wird. Sie wird in eine Nut eingefügt und dient dazu, die Bauteile zu fixieren und eine Drehmomentübertragung zu ermöglichen. Passfedern gibt es in verschiedenen Formen und Größen, je nach den Anforderungen der Anwendung. Sie sind eine gängige Methode, um eine sichere und zuverlässige Verbindung zwischen Bauteilen herzustellen.“* [OPE23a]

Außerdem die Antwort zum RWDR im Folgenden dargestellt:

*„Ein Radialwellendichtring ist ein Dichtungselement, das verwendet wird, um das Eindringen von Schmutz, Staub, Flüssigkeiten oder anderen Verunreinigungen in eine rotierende Welle oder Achse zu verhindern. Er wird in einer Gehäusebohrung montiert und umschließt die Welle, um eine abdichtende Wirkung zu erzielen. Der Radialwellendichtring besteht aus einem flexiblen Elastomer oder einem anderen Dichtungsmaterial und hat oft eine Metallhülse zur Stabilisierung. Er wird häufig in Maschinen, Motoren, Getrieben und anderen rotierenden Anwendungen eingesetzt, um eine zuverlässige Abdichtung zu gewährleisten und den Verschleiß der Bauteile zu reduzieren.“* [OPE23a]

Mit diesen Detektionen und Aussagen ist die KI in der Lage, die Funktion der Maschine fast vollständig zu erklären und die Übungsaufgabe zu lösen. Das Schlussfazit, dass es sich um ein Getriebe handelt, welches eine Kraftumlenkung um einen rechten Winkel erlaubt, bleibt dem Nutzer überlassen. *ChatGPT* ist nicht in der Lage, Bilder als Eingabe zu verarbeiten. Laut *OpenAI* wird daran zurzeit gearbeitet [OPE23b]. Damit wird die Aufgabe zu etwa 80% gelöst.

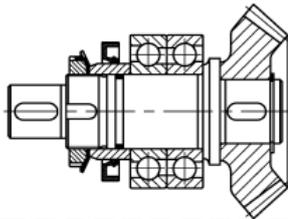
Als weitere Herausforderung für die KI, um die Fähigkeiten unter Beweis zu stellen, wird eine beispielhafte Klausuraufgabe herangezogen, welche in **Abbildung 6.9** dargestellt ist. Da laut der Analyse, welche im Projekt *TZ Digital.nrw* durchgeführt wurde, die meisten Hochschulen in NRW eine schriftliche Klausur verwenden, ist eine solche Aufgabe repräsentativ für den Fachbereich. Diese Aufgabe ist Teil der schriftlichen Prüfungsleistung zum Modul Technisches Zeichnen. Es handelt sich um eine Bemaßungsaufgabe, die neben Darstellungsaufgaben in der Klausur enthalten ist. Hier soll

eine dargestellte Welle im Maßstab 1:1 bemaßt werden. Die Abmessungen der Normteile sind den beigelegten Normtabellen zu entnehmen. Dafür muss zunächst erkannt werden, wo sich welche Teile auf der Welle befinden. Neben der Aufgabenstellung am oberen Bildrand ist die Welle mit aufgesetzten Bauteilen zu sehen. Ein Kegelzahnrad ist mit einer Passfederverbindung mit der Welle verbunden und axial durch einen Sicherungsring gesichert. Gelagert wird die Anordnung durch ein doppelreihiges Schrägkugellager in O-Anordnung. Dies wird gesichert durch eine Wellenmutter mit Sicherungsblech sowie einer dazwischenliegenden Distanzbuchse. Auf der Distanzbuchse befindet sich ein RWDR und darunter ein radial außendichtender O-Ring. Damit das Sicherungsblech montiert werden kann, ist eine Sicherungsblechnut in die Welle eingebracht. Darüber hinaus sind Freistiche und Fasen sowohl an der Welle als auch an der Distanzbuchse vorhanden. Am Wellenende befindet sich eine Passfedernut.

**Aufgabe E Bemaßung / Toleranzen**

Teilaufgabe	E-BEM	$\Sigma$
Max. Pktzahl	15	15
Erreichte Pktzahl		

**BEM-01** Bemaßen Sie die im Maßstab 1:1 die dargestellte Welle freihändig und vollständig. Beachten Sie dabei folgendes:



Maße und **zugehörige Toleranzen** sind durch Abmessen zu ermitteln bzw. den Tabellenwerten zu entnehmen. Verwendete Werte sind in den Tabellen zu **kennzeichnen**.

Form- und Lagetoleranzen sind nicht zu zeichnen. Oberflächenangaben sind nicht zu zeichnen. Die Mittellinie ist zu ergänzen.

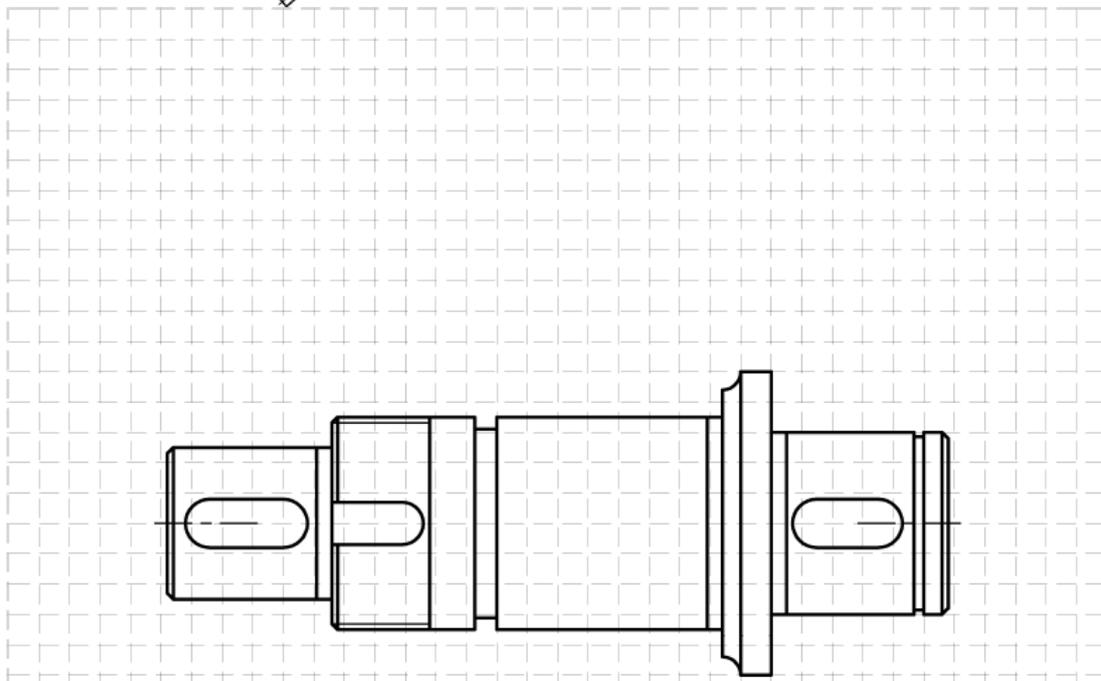


Abbildung 6.9: Beispielhafte Klausuraufgabe im Modul Technisches Zeichnen

Nachdem mit Messmitteln die Maße der Welle bestimmt wurden, können die identifizierten Bauteile der Normtabelle entnommen und eingezeichnet werden. Als Hilfestellung

für die Messung sind karierte Kästchen im Hintergrund hinterlegt, die ein Quadrat einer Größe von 5 x 5 Millimeter abdecken. Alle Abmessungen, die für die Fertigung der Welle benötigt werden, sind normgerecht einzuzeichnen. Toleranzangaben zu den Abmessungen sind zu ergänzen, wobei Form- und Lagetoleranzen sowie Oberflächenangaben nicht eingezeichnet werden müssen. Typische Bemaßungsfehler, wie zum Beispiel die Kettenbemaßung, sind zu vermeiden.

Im ersten Schritt müssen die vorhandenen Bauteile erkannt werden. Dafür wird zunächst die Welle, anhand der bemaßt werden soll, durch den KI-Detektor analysiert. Das Ergebnis ist in **Abbildung 6.10** abgebildet. Es werden drei Passfedern erkannt. Dieses Ergebnis ist nicht gänzlich korrekt, weil eine Sicherungsblechnut als Passfedernut gekennzeichnet wird. Diese Welle liegt ebenfalls in einer kleinen Auflösung und Größe vor, weil die Welle quer auf einem DIN A4 Hochformat dargestellt ist. Daraufhin wird die noch kleinere Darstellung der Welle mit aufgesetzten Bauteilen durch den KI-Detektor analysiert.

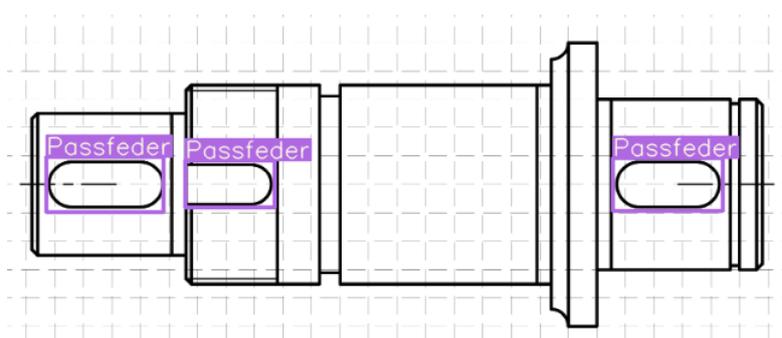


Abbildung 6.10: Erkennungen an der Welle zur beispielhaften Klausuraufgabe

Hierzu sind die Detektionen in **Abbildung 6.11** dargestellt. Es werden, wie oben, die Passfedern erkannt und die Sicherungsblechnut wird ebenfalls fälschlicherweise als Passfedernut markiert. Außerdem werden drei von vier Schrägkugellagern erkannt. Die Wellenmutter mit Sicherungsblech wird einmal von zwei vorhandenen Darstellungen erkannt. Der Gewindeabsatz wird entdeckt, die BB stimmt mit dem tatsächlichen Objektraum jedoch nicht vollständig überein. Zuletzt wird der Sicherungsring richtig markiert. Der RWDR wird nicht detektiert. Die Objekte Fase, Freistich, O-Ring und Distanzbuchse werden in diesem Stadium der KI-Entwicklung nicht angelernt.

Die Mehrheit der zu Bewältigung erforderlichen Objekte werden erkannt. Die Passfedergröße kann bei dem Vorliegen der Bildgröße und Auflösung angegeben werden. Dadurch kann ein Wellendurchmesser ermittelt werden. Dieses Vorgehen entspricht der Gegenrichtung der Aufgabenstellung, aus der die Abmessungen der Passfeder durch das Wissen des Wellendurchmessers zu ermitteln sind. Durch die zusätzlichen Informationen der KI-Detektion kann eine Konsistenzprüfung durchgeführt werden, ob die durch die

Studierenden ermittelten Werte korrekt sind. Nachdem die Objekte ermittelt werden, kann die KI durch eine Logik auf alle Maße schließen. Mit Hilfe dieser Informationen ist es jedoch nicht möglich, die Welle vollständig zu bemaßen. Dazu müssten die Daten zu den noch nicht angelernten Klassen vorliegen. Mit diesen Daten zur Position und Größe können Wellenabsätze durch einen Algorithmus bestimmt werden. Als Beispiel soll der linke Wellenabsatz dienen. Wenn Fasen und Freistiche markiert werden, kann auf die Länge des Wellenabsatzes geschlossen werden. Der Wellendurchmesser kann durch die Größe aus Fasen- und Freistichgröße ermittelt werden. Dies kann mit Hilfe der Passfedergröße und Normtabellen gegen geprüft werden. Es kommt zu Schwierigkeiten, wenn zu wenige Informationen zu Wellenabsätzen vorliegen. Beispielsweise ist der größte Wellenabsatz der Welle nicht sicher zu bestimmen. Dieser dient als axiale Anlagefläche für das Zahnrad sowie für die Schrägkugellager. Die axiale Länge kann mit Hilfe der Detektionen von Schrägkugellager und Freistichen berechnet werden. Der Durchmesser des Absatzes kann nur abgeschätzt werden, da keine Informationen dazu vorliegen.

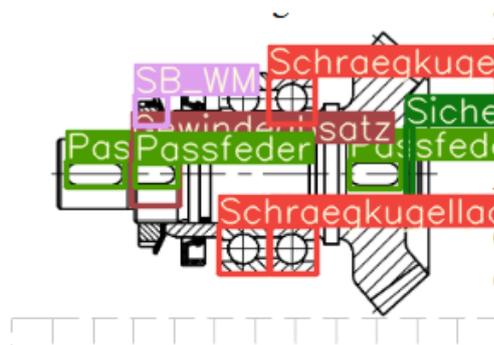


Abbildung 6.11: Erkennungen an der Bauteilzeichnung zur beispielhafte Klausuraufgabe

Die Erstellung von Bemaßungen bei dem Vorliegen der Abmessungen ist durch einen Algorithmus machbar. Die Herausforderung stellt jedoch der Gesamtzusammenhang dar, weil für eine fertigungsgerechte Bemaßung immer der Gesamtkontext berücksichtigt werden muss. Außerdem kann es durch die Aneinanderreihung von Maßen zu Fehlern wie der Kettenbemaßung kommen. Dies kann zwar durch den Algorithmus vermieden werden, indem das Vorhandensein von nebenstehenden Maßen geprüft wird. Im Gesamtkontext muss betrachtet werden, welche Fertigungsschritte wann durchzuführen sind. Auf diesem Gedanken baut beispielsweise die Festlegung einer Maßbezugs-kante auf. Diese Festlegung ist zwar durch eine Logik festlegbar, allerdings ist es in einigen Fällen schwierig, für einen Algorithmus eine solche Maßbezugs-kante festzulegen. Ein weiteres Problem stellen die falsch positiven Erkennungen dar. In diesem Beispiel wird eine Passfedernut falsch positiv erkannt. Hier kann eine Plausibilitätsprüfung insofern durchgeführt werden, als dass sich eine Passfeder nicht im Bereich eines Gewindeabsatzes oder zwischen Wellenmuttern befinden darf.

Insgesamt ist die KI bezüglich der beispielhaften Prüfungsaufgabe im Stande, die Grundlagen der Aufgabenstellung zu erfüllen. Allerdings können Bemaßungen nicht vollständig erstellt werden. Die Angabe von Toleranzangaben kann automatisiert werden, weil diese einem Tabellenwerk entnommen werden können. Wenn ein Algorithmus zur Bemaßung der Welle entwickelt wird, kann dieser etwa 80% der Aufgabenstellung erfüllen. Es ist jedoch nicht abschätzbar, ob jegliche Bemaßungsfehler vermieden werden können. Insgesamt kann die KI bezüglich dieser Aufgabe bei wichtigen Grundlagen, der Identifikation von Bauteilen, unterstützen. Sie ist nicht in der Lage, die Aufgabe eigenständig fehlerfrei zu lösen, weil viele Aspekte berücksichtigt werden müssen.

Im Technischen Zeichnen kann die KI überall dort unterstützen, wo Objekte erkannt und Aufgaben von Normteilen beschrieben werden müssen. Bei Aufgaben, in denen die Studierenden eigene Zeichnungen erstellen sollen, stößt die KI an Ihre Grenzen. Das Anfertigen von Darstellungszeichnungen und Bemaßungsaufgaben können nicht gänzlich gelöst werden. Bei der Identifikation von Bauteilen, also der Kompetenz zum Lesen und Interpretieren technischer Zeichnungen, kann die KI die Studierenden unterstützen. Da in niedrigen Kompetenzstufen häufig Wissen abgefragt wird, bei dem die KI mittels *ChatGPT* unterstützen kann, bieten sich zunächst alle in Abschnitt 5.1.2 genannten Themen für den Einsatz an.

### **6.2.2 Anwendungsszenario für die potenzielle Integration in die Lehrveranstaltungen**

Die Lehrveranstaltung zum Technischen Zeichnen (Fächer werden an anderen Hochschulen anders genannt) ist an den Hochschulen in Nordrhein-Westfalen in Vorlesung und Übung aufgeteilt. Dazu kommt das Selbststudium, in dem sich die Studierenden mit dem gegebenen Lernmaterial den Lernstoff selbst aneignen sollen. Im Durchschnitt werden 60 Stunden für die Präsenzzeit und 90 Stunden für das Selbststudium angegeben (siehe Anhang F Abbildung F.3). Das Fach wird durchschnittlich mit vier Semesterwochenstunden und 4,7 Leistungspunkten im arithmetischen Mittel ausgeschrieben (siehe Anhang F Abbildung F.1 und Abbildung F.2).

Es bietet sich an die Unterstützung der KI in den Phasen des Selbststudiums zu platzieren, da in der Präsenzveranstaltung die Dozierenden tätig sind. Die KI kann den Studierenden zunächst helfen, Aufgaben in Ihrem Grundsatz zu verstehen. Bei der Vorbereitung auf die Vorlesung und besonders auf die Übung können einfache Grundlagen schnell ermittelt werden. Beispielsweise befasst sich eine der ersten Übungen im Technischen Zeichnen mit der Darstellung von Bauteilen. Ansichten zu benennen oder weitere Ansichten eines Bauteils zu zeichnen ist ein Aufgabentyp innerhalb der Übung. Wenn die Studierenden keinerlei Vorwissen zum Thema Ansichten mitbringen,

kann *ChatGPT* helfen, diese Wissenslücke schneller zu schließen, sodass die anvisierte Aufgabe gelöst werden kann.

Die meisten Studierenden bewerten das Thema zielorientierte Bemaßung als wichtig für den weiteren Studienverlauf (siehe Anhang E Abbildung E.6(b)); es sollte jedoch wie bisher gewichtet werden (siehe Anhang E Abbildung E.11(b)). Die Studierenden haben die OER-Angebote zum Thema zielorientierte Bemaßung wenig genutzt (siehe Anhang E Abbildung E.40(a)). Diejenigen, die die Lernmaterialien genutzt haben, bewerten die Darstellung als sehr verständlich, medial gut aufbereitet und interaktiv dargestellt, sodass die Materialien beim Lernen und bei der Prüfungsvorbereitung eine gute Unterstützung darstellen (siehe Anhang E Abbildung E.40 bis Abbildungen E.44). In Bezug auf die in dieser Arbeit entwickelte KI-Objekterkennung stehen also folgende potenzielle Szenarien im Fokus. Bei Bemaßungsaufgaben müssen häufig Fehler erkannt werden. Bemaßungsfehler sind die Doppel- und Kettenbemaßung, die falsche Maßlinienbegrenzung und das Fehlen von Symbolen wie Durchmesserzeichen. Die KI-Objekterkennung kann potentiell für solche Anwendungen trainiert werden. Für das Thema Toleranzen und Passungen existieren Aufgaben, in denen die Studierenden Werte aus Tabellenwerken einer Norm entnehmen sollen. Bei dieser Aufgabe kann die KI unterstützen, allerdings sind auch einfachere Programmieranwendungen in der Lage, in diesem Fall als Hilfe zu dienen. Das Thema Toleranzen und Passungen wird von den Studierenden als eher wichtig angesehen (siehe Anhang E Abbildung E.8(b)). Zu diesem Thema werden die Inhalte begrenzt genutzt (siehe Anhang E Abbildung E.60(a)). Auch hier werden die Verständlichkeit, die mediale Aufbereitung und die Interaktion positiv bewertet (siehe Anhang E Abbildung E.61(a) bis Abbildung E.64).

Eine weitere Aufgabe besteht darin, Schriftfelder in TZ auszufüllen. Die KI kann bei der Erstellung von Stücklisten unterstützen, indem Bauteile durch den KI-Detektor erkannt werden, und die dazugehörigen Informationen wie Bezeichnung, Stückzahl und Einheit in die Stückliste eintragen. Allerdings kann diese Tabelle nicht vollständig durch die KI ausgefüllt werden, weil Informationen zum verwendeten Material nicht vorliegen und dies von Faktoren abhängt, die zurzeit ein Mensch bewerten muss. Diese Faktoren können sein, Fremd- oder Eigenfertigung, Kosten, Einsatzgebiet, Belastungen etc., die untereinander zusammenhängen können. Diese Auswahl ist sehr kompliziert und lässt sich mit den vorliegenden Fähigkeiten der KI nicht durchführen.

Wie bereits erwähnt ist die KI in der Lage beim Lesen und Interpretieren technischer Zeichnungen zu unterstützen. Dies setzt allerdings voraus, dass die KI-Detektion auf die Objekte, die in der Zeichnung vorkommen, vorher angelernt wurde. Das mag bei Normteilen recht einfach sein und zuverlässig funktionieren, doch bei Maschinen mit vielen nicht standardisierten Bauteilen stößt die KI-Detektion an ihre Grenzen. Als Beispiel ist ein Locher zu nennen, bei dem die meisten Teile individuell gestaltet sind.

Das einzige Normteil, das verwendet wird, ist in der Regel eine Feder, damit Stempel und Handhebel wieder in die Ausgangsstellung zurück verfahren.

Für den Fall, dass die KI-Detektion in TZ 90% der Bauteile erkennt, ist es oftmals schwierig auf die Gesamtfunktion zu schließen. Dafür bedarf es selbst beim Menschen an einem soliden Grundwissen und Erfahrung. Zum Thema Normteile und Maschinenelemente ist in den Umfragen auffällig, dass die Studierenden dieses Thema als äußerst wichtig ansehen (siehe Anhang E Abbildung E.7(b)). Trotz der positiv bewerteten Darstellungsweise werden die Materialien dazu wenig genutzt (siehe Anhang E Abbildung E.50 bis Abbildung E.54). Das bedeutet, dass hier aufgrund der Wichtigkeit des Themas eine Unterstützung durch die KI empfehlenswert ist. Ähnliches trifft auf das Thema Schraubenverbindungen zu (siehe Anhang E Abbildung E.55 bis Abbildung E.59). Diese Thema wird allerdings als nicht äußerst wichtig, sondern eher wichtig durch die Studierenden angesehen (siehe Anhang E Abbildung E.8(a)).

Schlussendlich ist die KI in der Lage, den Studierenden oder die Ingenieur\*innen bei manchen Themen zu unterstützen, allerdings muss zwangsläufig zusätzliche Arbeit investiert werden, weil die KI nicht in der Lage ist, Aufgaben selbstständig zu lösen. Die KI kann potenziell eine prüfende Funktion übernehmen, indem die KI auf eine Fehleranalyse trainiert wird. Damit können frühzeitig Fehler in der Produktentwicklung aufgedeckt werden, die sich zeitlich exponentiell auf die Kosten auswirken. Für die Aufgabe, Studienleistungen wie Getriebekonstruktionen zu bewerten, fehlt es an Fähigkeiten, allerdings ist eine Vorkorrektur möglich.

Zuletzt soll ein potenzielles Lernszenario als Beispiel angeführt werden, welches die Umsetzung eines Spielkonzeptes für die Lehre mit der KI-Detektion kombiniert. Es soll der Gamification Ansatz aus dem Stand der Technik genutzt werden. In den letzten beiden oder in der letzten Veranstaltung der Übung werden im Modul Technisches Zeichnen klausurvorbereitende Themen behandelt und klausurähnliche Aufgaben diskutiert. Hier können die Lehrenden bspw. eine Herausforderung planen, in der die Studierenden gegen die KI-Detektion antreten sollen. Eine TZ themenübergreifend zu analysieren, ist hier als beispielhafte Aufgabe anzuführen. Anhand der Schnittdarstellung eines Getriebes, welches beispielsweise aus dem Konstruktionsprojekt stammt, sollen alle auf der Welle befindlichen Bauteile sowie die geometrischen Elemente der Welle ausfindig gemacht und benannt werden. Am Ende wird eine Punktzahl ausgegeben, wie viele Punkte von der Maximalpunktzahl erreicht werden inklusive einer prozentualen Angabe. Danach startet die KI-Detektion mit der Erkennung der Bauteile. Im Anschluss wird das Ergebnis der KI ermittelt und mit dem der Studierenden verglichen. Um die Aufgabe zu motivieren, können Belohnungen in Form von Bonuspunkten oder einer Bonuszeit für die Klausur vergeben werden.

### 6.2.3 Unterstützung für weitere Lernszenarien

Weitere Lehrveranstaltungen, die auf das Technische Zeichnen folgen, behandeln die Maschinenelemente. Hier kann die KI-Detektion ebenfalls unterstützen. Inwiefern dies möglich ist, wird in Folgendem diskutiert. An der TU Dortmund werden die Module Maschinenelemente I, II und III gelehrt, die an anderen Hochschulen andere Namen tragen. Es wird eine Analyse durchgeführt, welche Themen an Hochschulen in Nordrhein-Westfalen gelehrt werden. Dabei geht es hauptsächlich um die im Folgenden aufgelisteten Themen (siehe Anhang G Abbildung G.6):

- Werkstoffe und Werkstoffeigenschaften ,
- Festigkeitsberechnung,
- Gestaltung und Gestaltungsregeln (Guss- und Schweißkonstruktionen),
- Dichtungen,
- Achsen und Wellen,
- Welle-Nabe-Verbindungen,
- Wälzlager,
- Zahnräder,
- Federn,
- Schraubenverbindungen,
- Nietverbindungen,
- Gleitlager,
- Schweißverbindungen,
- Lötverbindungen,
- Klebverbindungen,
- Riemen und Ketten,
- Kupplungen,
- Linearführungen.

Im Thema Werkstoffe und Werkstoffeigenschaften sowie Festigkeitsberechnung geht es um die Werkstoffauswahl und Berechnung von Konstruktionen. Hier kann *ChatGPT* eine sinnvolle Hilfe sein. Das Thema Gestaltung handelt von der konstruktiven Entwicklung eines Produktes wie zum Beispiel einer Maschine. Es ist im Rahmen des Möglichen, dass die KI -Detektion auf das Finden von konstruktiven Fehlern trainiert wird und somit zu diesem Thema assistieren kann. Außerdem kann die KI bei der Gestaltung von

Maschinen unterstützen. Zu den anderen Themen, die oben aufgelistet sind, eignet sich die KI-Detektion weniger als Unterstützung. Innerhalb dieser Bereiche kann *ChatGPT* bei der Klärung von Grundlagen helfen. Innerhalb dieser Themen werden oft der Aufbau und die Funktion der Elemente behandelt. Außerdem geht es um die Berechnung der Ausführungen und deren Lebensdauer. Hierzu fällt es schwer, einen geeigneten Ansatz zu ermitteln, bei dem die KI geeignete Hilfe bereitstellt, weil die benötigten Fähigkeiten zur Lösung der interdisziplinären Problemstellungen nicht gegeben sind.

Laut Anhang G Abbildung G.1 ist der Modulumfang bei den Hochschulen in NRW zumeist sehr ähnlich. Im genannten Diagramm sind die Hochschulen auf der Abzisse und der Umfang in Stunden auf der Ordinate aufgetragen. Es werden die Präsenzzeit, das Selbststudium und der gesamte Workload getrennt dargestellt, die jeweils um den Mittelwert ergänzt werden. Die Mittelwerte liegen bei etwa 130 Stunden Präsenzzeit, 180 Stunden Selbststudium und in Summe 310 Stunden Workload. Darin werden alle Module eingerechnet, die sich mit den Maschinenelementen auseinandersetzen. Pro Hochschule sind das eins bis vier Module. Damit ergeben sich der durchschnittliche Workload pro Leistungspunkt zu 30 Stunden pro LP (siehe Anhang G Abbildung G.4) und die durchschnittlichen SWS pro Semester für ein Modul von vier. Die Prüfungsleistung ist zumeist eine schriftliche Klausur und mehr als 70% der Hochschulen vergeben acht bis 15 CP/LP für das gesamte Modul (siehe Anhang G Abbildung G.2 und Abbildung G.3). In Abbildung G.3 des Anhangs G ist neben dem Tortendiagramm zunächst die Anzahl der Hochschulen und danach der prozentuale Anteil angegeben. Da das Modul Maschinenelemente viele Hochschulen sehr ähnlich lehren, bietet sich ein Angebot als OER an, bei dem die KI integriert werden kann.

Zur Unterstützung der konstruktiven Gestaltung in der Lehre oder Produktentwicklung kann die KI in dem im Folgenden beschriebenen Szenario eine sinnhafte Hilfe darstellen. Eine TZ kann bspw. durch das reverse Engineering digitalisiert werden, oder ein Konstrukteur\*in möchte eine Zeichnung in dreidimensionaler Ansicht außerhalb des CAD-Systems virtuell betrachten können. Besonders kann es im Grundstudium des Ingenieurwesens vorkommen, dass zweidimensionale Zeichnungen von Maschinen wie Getrieben konstruiert werden, und eine Betrachtung der dreidimensionalen Darstellung nicht möglich ist, weil in einem 2D-CAD Programm oder per Hand auf Papier konstruiert wird. In diesen Fällen bietet es sich an, die TZ in eine dreidimensionale Umgebung zu übertragen. Darüber hinaus hat sich die virtuelle Technologie (VR) so weit entwickelt, dass geeignete Produkte auf dem Markt vorhanden sind, die sich der Verbraucher leisten kann und deren Leistung ausreicht, um anspruchsvolle grafiklastige Programme ausführen zu können. Die VR-Technologie bietet sich an, um das räumliche Vorstellungsvermögen zu schulen. Verschiedene Veröffentlichungen haben den Einfluss der Betrachtungsmöglichkeit in VR auf das räumliche Vorstellungsvermögen untersucht.

Die Ergebnisse dieser Untersuchung sind, dass eine VR-Umgebung das Ausbauen des räumlichen Vorstellungsvermögens effektiver macht, weshalb in gleicher Zeit ein höheres Kompetenzlevel erreicht werden kann, und dass es in der Lage ist, die Zeit für eine sehr gute Vorstellungsfähigkeit eines 3D-Objektes um ein Vielfaches zu verkürzen [Abd13; SK03; Vor19; Pan09; SB07; Pa22].

In einem Konstruktionsprojekt sollen Studierende ein ein- oder zweistufiges Getriebe konstruieren, welches als Hausarbeit anzufertigen ist. Mit individuellen Auslegungsdaten unterscheiden sich die Getriebe in verschiedener Hinsicht. Darüber hinaus muss eine Belastungsanalyse durchgeführt werden, ob das Getriebe den Kräften standhält. Bei der Auswertung dieser Prüfungsleistung ist aufgefallen, dass die Studierenden teilweise Probleme haben, sich ihre eigene Konstruktion räumlich vorzustellen. Aus diesen Voraussetzungen ist die Idee entstanden, eine Software zu entwickeln, die das individuell konstruierte Getriebe in eine VR-Umgebung transferiert, um in dieser das räumliche Vorstellungsvermögen sowie andere Kompetenzen zu schulen. Die KI-Detektion soll die Bauteile in der Zeichnung erkennen. Danach werden die Erkennungen samt Informationen über eine json-Datei an die VR-Software übergeben. Als Software kann die Spielentwicklungssoftware *Unity* genutzt werden, welche Erweiterungen für die VR-Technologie bereitstellt. Innerhalb dieser Umgebung können beispielsweise Montageaufgaben oder Simulationen ausgeführt werden. Diese Software wird in einem aktuellen Projekt entwickelt und soll ab dem Jahr 2024 für die Lehre zur Verfügung stehen.

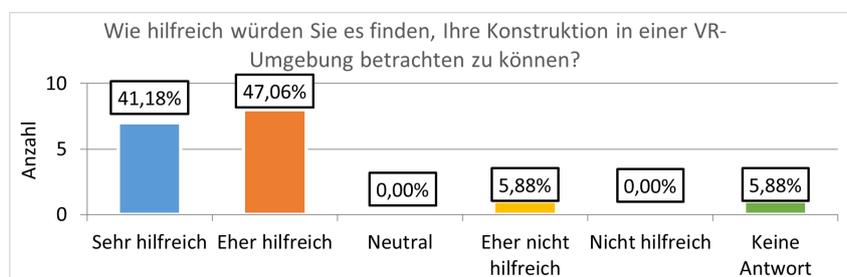


Abbildung 6.12: Bedarf der Integration von VR nach [Dok23]

Die während der Betreuungsphasen durchgeführten Umfragen begründen diesen Bedarf der Unterstützung. In den Umfragen geht es um die Konstruktion des zweistufigen Getriebes, welche als Hausarbeit angefertigt werden soll. Während dieser Hausarbeitszeit, die ein Semester andauert, haben die Studierenden die Möglichkeit, Fragen mit einem persönlichen Betreuer während Sprechstunden zu klären. Die Umfrage wurde am Ende der Konstruktionsprojekte vor der Abgabe durchgeführt. Diese Umfragen ergeben, dass die Studierenden eine Betrachtung der Konstruktion in VR als hilfreich oder sehr hilfreich betrachten und konstruktive Fehler der eigenen Konstruktion erst spät erkannt wurden, weshalb große Teile der Konstruktion angepasst werden mussten (siehe **Abbildung 6.12** und **Abbildung 6.13**). Die KI kann hier unterstützen, um frühzeitig

Fehler zu erkennen und das Lernen zu erleichtern. Dies geht mit einem geringeren Betreuungsaufwand einher. [Dok23]

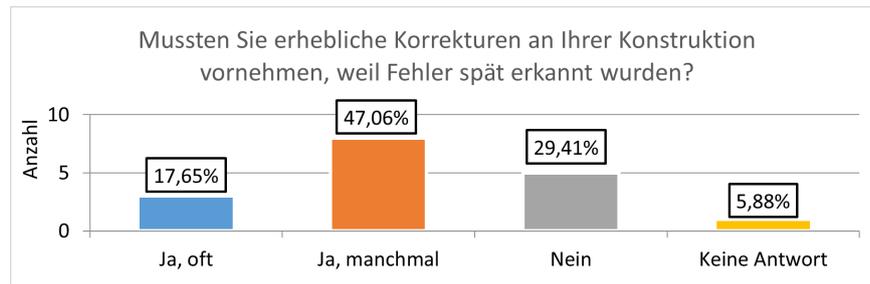


Abbildung 6.13: Bedarf der Integration von VR II nach [Dok23]

Für die Schaffung eines solchen Angebotes müssen allerdings die Rahmenbedingungen geschaffen werden. Laut der **Abbildung 6.14** besitzen mehr als 80% der Studierenden kein VR-Headset und haben mehrheitlich auch keinen Zugriff durch Verwandte oder Freunde. Das bedeutet, dass hier ein Angebot seitens der Lehre geschaffen werden muss, das die Nutzung der Technik ermöglicht. Eine andere Möglichkeit ist die Nutzung einfacher VR-Technik mittels Smartphones ohne Controller. Dies hemmt jedoch stark die Immersion und die Lerneffektivität, weil die Interaktionen durch die begrenzten Eingabemöglichkeiten eingeschränkt sind. Erste Lernräume, in denen die VR-, AR-, und XR-Technologie von Studierenden genutzt werden kann, gibt es mittlerweile. Durch die steigende Anzahl solcher Angebote und die größere Verfügbarkeit von VR-Headsets auf den Markt, welche im Preis eine fallende Tendenz aufweisen, wird sich die Situation zur Verfügbarkeit für Studierende verbessern. Falls Studierende ein VR-Headset besitzen, befindet sich ein preisgünstiges Modell in Ihrem Besitz. Dies deutet darauf hin, dass diese Technologie aus Kosten-Nutzen-Sicht nicht für diese Zielgruppe attraktiv ist, weil Sie zu teuer ist. [Dok23]

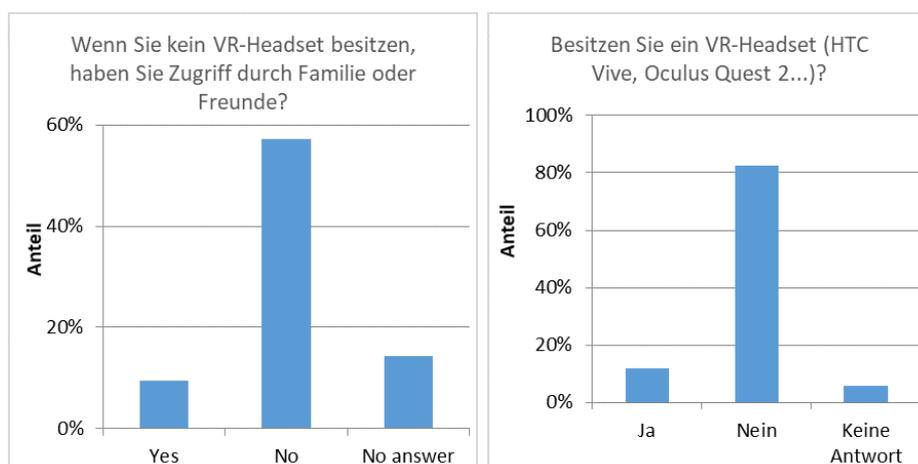


Abbildung 6.14: VR-Headset Besitz und Verfügbarkeit nach [Dok23]

# 7 Analyse und Bewertung des Niveaus der KI

Anhand der vorangegangenen Entwicklungen wird die Leistungsfähigkeit der Objektdetektion analysiert und diskutiert. Es wird evaluiert, welche der in Kapitel 5 definierten Kompetenzstufen die KI im Status quo erreicht. Dabei wird auch berücksichtigt, welchen Stand andere KI-Modelle wie *ChatGPT* dazu beitragen, um die genannten Niveaus zu erreichen. Zu dem Zweck der begründeten Nachvollziehbarkeit wird ein Punktesystem eingeführt, damit die KI mit Studierenden und Ingenieuren verglichen werden kann (Turing Test). Dieses Punktesystem wird im Nachfolgenden aufgeführt:

- 0 Punkte: Keine definierte Kompetenz erreicht,
- 1 Punkt: Niedrige Kompetenzstufe gerade eben erreicht,
- 2 Punkte: Niedrige Kompetenzstufe teilweise erreicht,
- 3 Punkte: Niedrige Kompetenzstufe vollständig erreicht,
- 4 Punkte: Mittlere Kompetenzstufe gerade eben erreicht,
- 5 Punkte: Mittlere Kompetenzstufe teilweise erreicht,
- 6 Punkte: Mittlere Kompetenzstufe vollständig erreicht,
- 7 Punkte: Hohe Kompetenzstufe gerade eben erreicht,
- 8 Punkte: Hohe Kompetenzstufe teilweise erreicht,
- 9 Punkte: Hohe Kompetenzstufe vollständig erreicht,
- 10 Punkte: Alle Kompetenzstufen erreicht und interdisziplinär anwendbar.

Bei den 10 vorgegebenen Themen (CAD wird ausgeklammert) können insgesamt maximal 100 Punkte erreicht werden, sodass eine Bewertung im Vergleich zu Klausurergebnissen vorgenommen werden kann.

## 7.1 Analyse und Bewertung der Kompetenzstufen nach Thema

Die KI mit Hilfe von *ChatGPT* in der Lage, eine TZ in den Konstruktionsprozess einzuordnen. Das in Abschnitt 5.3.1 erklärte Niveau wird erreicht. Deshalb erreicht diese in diesem Teil **10 Punkte**.

In Bezug auf die Grundlagen der Freihandzeichnungen erreicht die KI alle geforderten Punkte des geringen fachlichen Anspruchs bis auf die Erstellung von Zeichnungen einfacher Bauteile. Die weiteren Kompetenzstufen werden nicht erreicht, weshalb hier **2 Punkte** vergeben werden.

Bei dem Thema Ansichten und Dreitafelprojektion werden Teile der in Abschnitt 5.3.3 genannten Punkte des einfachen Kompetenzniveaus erfüllt. Die Ansichten können benannt werden und der Schattenriss kann erklärt werden. Zeichnungen zu Projektionen kann die KI nicht erstellen. Die nächsten Schwierigkeitsstufen werden nicht erreicht. Die KI kann Zeichnungselemente zwischen Ansichten nicht zuordnen. Dafür müsste die KI die verschiedenen Bauteile in den einzelnen Ansichten erkennen. Dies ist in detailreichen Schnittansichten möglich, jedoch wird der KI das Können bei anderen Ansichten abgesprochen. Demnach müsste eine Zuordnung der Bauteile stattfinden. Insgesamt erreicht die KI **2 Punkte**.

Wie im Stand der Technik beschrieben, kann die KI-Detektion Bemaßungen und Bemaßungselemente in TZ erkennen. Die KI kann die Grundlagen der Bemaßung beschreiben und zwischen fertigungs-, funktions- und prüfgerechter Bemaßung unterscheiden. Es ist möglich, dass die KI das mittlere Kompetenzniveau erreicht, da das Erkennen von Bemaßungsfehlern trainiert werden kann. Ob alle Fehler zuverlässig detektiert werden können, ist fraglich. Die Bemaßung innerhalb einer Zeichnung nach fertigungs-, funktions- und prüfgerechter Bemaßung zuzuordnen, befindet sich außerhalb der Kompetenz der KI. Die Bestimmung der Maßbezugskante ist durch eine Logik bestimmbar. Die restlichen Punkte der Kompetenz werden nicht erreicht. Deshalb erhält die KI zum Thema zielorientierte Bemaßung **5 Punkte**.

In Bezug auf das Thema Schnitte und Zeichnungsgruppen erreicht die KI teilweise die mittlere Kompetenzstufe. Die KI ist in der Lage, den Aufbau von Stücklisten zu erklären und die Regeln zum Anbringen von Positionsnummern benennen. Die Zuordnung der Bauteile kann durch die Erkennung von Positionsnummern vollbracht werden. Ob Teil-, Halb- und Vollschnitte unterschieden werden können ist fraglich. Einzelne Teile können in Zusammenbauzeichnungen erkannt werden, allerdings nicht alle. Auf dem Niveau mittleren fachlichen Anspruchs kann der Punkt lesen und erstellen von Stücklisten zu großen Teilen durchgeführt werden. Die Analyse der Bauteile in Zusammenbauzeichnungen kann zum Teil funktionieren, ist aber als kritisch zu betrachten. Der erste Punkt des Einzeichnens von Teil-, Halb- und Vollschnitte ist nicht möglich. Hier werden **5 Punkte** vergeben.

Der geringe fachliche Anspruch zum Thema Normung und GPS (Geometrische Produktspezifikation) wird durch die KI erreicht. Eine Norm kann einem Bauteil zugeordnet werden, wenn letzteres als Objekt erkannt wird und eine Logik eine Verknüpfung zur Norm herstellt. Beim mittleren Niveau kann *ChatGPT* die Gestaltabweichungen benen-

nen, wenn die Eingabe des Nutzens präzise ist. Wie in Anhang H gezeigt, können bei nicht präzisen Formulierungen falsche Ergebnisse resultieren. Im genannten Anhang sind nicht die geforderten Gestaltabweichungen benannt, sondern es sind Form- und Lagetoleranzen aufgelistet. Bei der Durchführung einer Tolerierung können diese jedoch nicht in den Gesamtkontext gesetzt werden. Eine Toleranzanalyse kann die KI nicht selbstständig durchführen. Das bedeutet, dass der mittlere fachliche Anspruch teilweise erfüllt ist. Daher wird die Leistung der KI zu diesem Thema mit **4 Punkten** bewertet.

Beim Thema Toleranzen und Passungen wird die einfache Taxonomiestufe teilweise erreicht, weil nicht alle Aussagen gänzlich korrekt sind. Wenn *ChatGPT* weiter trainiert wird, können die in Abschnitt 5.3.7 genannten Punkte vollständig erreicht werden. Auf mittlerem Niveau ist die KI in der Lage, Toleranzen zu ermitteln, wenn die dafür benötigten Daten erkannt werden. Die Analyse einer Toleranzkette und das Auslegen von Maßketten befindet sich außerhalb der Kompetenz der KI. Dafür müssen die Maße und Toleranzen nicht nur erkannt werden, sondern auch bei der Berechnung der Kette die Werte untereinander verknüpft werden. Die Erkennung einer Form- und Lagetoleranz kann durch die Detektion der Symbole erfolgen. Eine Bestimmung der Form- und Lagetoleranzen ist möglich. Der hohe fachliche Anspruch wird nicht erreicht. Da die KI teilweise das mittlere Niveau erreicht, werden **5 Punkte** vergeben.

In Bezug auf das Thema Normteile und Maschinenelemente (inklusive Schraubenverbindungen) kann die KI mittels *ChatGPT* Normteile aufzählen und den Aufbau beschreiben. Die KI kann Normteile nicht direkt in TZ einzeichnen. Es müsste ein Bild des Normteils aus einer Bibliothek entnommen werden und in die Zeichnung eingefügt werden. Mit überschaubarem Programmieraufwand ist dies möglich. Die Objekterkennung ist in der Lage, Komponenten von Schraubenverbindungen zu erkennen, wenn dies angelernt wird. Der geringe fachliche Anspruch wird zu einem großen Teil erfüllt. Das mittlere Niveau erfüllt die KI nicht vollständig. Die Auswahl sämtlicher Norm- und Maschinenteile für eine Anwendung erfolgt nicht im interdisziplinären Belastungskontext. Kraftverläufe einzuzeichnen und zu analysieren ist eine Eigenschaft, die nicht erfüllt wird. Die Entnahme aus Normen und das Einfügen von Normteilen in TZ ist möglich. Die Analyse von Normteilen in einer TZ kann ebenfalls durchgeführt werden, weil der KI-Detektor Bauteile erkennen und *ChatGPT* die Funktion beschreiben kann. Da die meisten Punkte der mittleren Kompetenzstufe nicht erreicht werden, erhält die KI zu diesem Thema eine Bewertung von **4 Punkten**.

Im Bereich der Wellenbearbeitung wird das niedrige Kompetenzniveau erreicht, weil Fertigungsverfahren benannt und beschrieben werden, sowie der Aufbau einer Welle und deren Elemente benannt werden. Die KI kann die Komponenten einer Welle mit Hilfe der Detektion erkennen (Freistiche, Fasen etc.) und diese mit Normen in Verbindung bringen. Eine Welle kann analysiert werden, indem anhand eine Fertigungsbeschreibung

erstellt werden kann, beherrscht die KI nicht. Das hohe Niveau wird nicht erreicht, da ein Wellenfertigungsprozess nicht durch die KI geplant werden kann. Aus den genannten Gründen werden **5 Punkte** vergeben.

Das Lesen und Interpretieren technischer Zeichnungen auf einem niedrigen Level beherrscht die KI, weil der Aufbau einer Zeichnung beschrieben und Elemente bzw. Objekte innerhalb einer TZ benannt werden können. Es kann nicht beschrieben werden, welche Ansicht zu sehen ist. Mittlerer und hoher fachlicher Anspruch werden nicht erreicht, da die KI keine Analyse zur Gesamtfunktion einer Maschine bereitstellen kann. Für das letzte Thema werden **2 Punkte** zur Bewertung der KI-Fähigkeit vergeben.

Tabelle 7.1: Vergleich der Punkteverteilung zwischen KI und Studierenden

Thema	Punkte KI	Punkte Studierende
Einordnung in den Konstruktionsprozess	10	8,5
Grundlagen der Freihandzeichnungen	2	8
Ansichten und Dreitafelprojektion	2	9
Zielorientierte Bemaßung	5	8
Schnitte und Zeichnungsgruppen	5	8
Normung und GPS	4	7
Toleranzen und Passungen	5	7
Normteile und Maschinenelemente	4	6
Wellenbearbeitung	5	5
Lesen und Interpretieren von TZ	2	4,5
Gesamtpunktzahl	44	70

Insgesamt erreicht die KI mit Ihren derzeitig möglichen Fähigkeiten eine Gesamtpunktzahl von **44 Punkten** in Summe (siehe **Tabelle 7.1**). Damit wird die Hälfte der maximal erreichbaren Punktzahl von 50 Punkten nicht erreicht. Das führt in der Regel zu einem Klausurergebnis von ausreichend bis nicht bestanden. Der geringe fachliche Anspruch wird in den meisten Fällen erfüllt. Teilweise wird der mittlere fachliche Anspruch erreicht. Das hohe fachliche Niveau wird in keinem Fall erfüllt.

### 7.1.1 Vergleich der erreichten Kompetenzstufen zwischen Studierenden, Ingenieur und KI

Die durchschnittliche Klausurnote im Modul Technisches Zeichnen der letzten Jahre liegt im Bereich von 2,3. Dies entspricht einem Erreichen von etwa 70% der Maximalpunktzahl. Der Notendurchschnitt einer Klausur, welche am Ende eines Semesters gestellt wird, überstiegt die in Tabelle 7.1 erreichte Punktesumme der KI. Die Studierenden haben

am Ende der Veranstaltung ein höheres Niveau erreicht, als die KI es momentan vermag. Bei den niedrigeren Kompetenzen schneidet die KI besser als der Durchschnitt ab. Wenn die KI in der Lage ist, alle Bereiche des Maschinenbaus interdisziplinär betrachten zu können, können potentiell höhere Kompetenzen erreicht werden. Dafür müssten die Inhalte insgesamt und untereinander verknüpft angelernt werden. Dieses fächerübergreifende Wissen und die Erfahrung eines Ingenieurs bzw. einer Ingenieurin einer KI anzutrainieren, stellt einen großen Aufwand dar und würde große Kapazitäten einnehmen. Da einige Tätigkeiten, wie das Konstruieren von Maschinen, sich nur sehr schwer oder nicht automatisieren lassen, ist es nicht absehbar, dass die KI den Ingenieur bzw. die Ingenieurin in naher Zukunft ersetzen kann. [Kü23]

Im Stand der Technik wurde der Ingenieurberuf als einer der am schwierigsten zu automatisierenden Berufe beschrieben [Kap17]. In Anbetracht, dass das Technische Zeichnen ein Grundlagenfach für den Ingenieur bzw. die Ingenieurin darstellt und der Schwierigkeitsgrad im Verlaufe des Studiums zunimmt, ist das Ergebnis unter dem Gesichtspunkt, dass die KI eine/n Ingenieur/in ersetzen soll, als schwach zu bewerten. Der derzeitige Stand der KI-Fähigkeiten reicht aus, die Ingenieur\*innen oder die Studierenden bei einfachen Tätigkeiten unterstützen zu können. Es ist nicht möglich, dass die KI eigenständig Ingenieuraufgaben vollständig bewältigen kann. Ein ausgebildeter Maschinenbauingenieur\*in erreicht die hohen Kompetenzstufen des Technischen Zeichnens teilweise oder gänzlich, da es zur Grundsprache im Ingenieurwesen zählt.

### **7.1.2 Wo kann das Tool bzgl. der erreichten Kompetenzstufen generell im Maschinenbau eingesetzt werden?**

Durch die in diesem Kapitel herausgestellten Ergebnisse lassen sich die Anwendungsfelder der KI im Ingenieurwesen einschränken. Es existieren bereits Anwendungsfälle, bei denen die KI im Kundensupport unterstützt. Die KI hilft besonders bei den ersten Schritten der Fehlerbehebung. Teilweise wird dies von der Deutschen Telekom eingesetzt, wenn das Internet beim Kunden nicht funktioniert [Deu23]. Dies kann auch auf das Ingenieurwesen übertragen werden, wenn Maschinen bedingt durch Fehler ausfallen. In den meisten Fällen reichen einfache Handlungen aus, die der Kunde selbst oder ein/e fachmännische/r Techniker/in erledigen kann. Nur bei schwerwiegenden Ausfällen müssen dann die Experten (Ingenieure) tätig werden, womit für das Unternehmen Kosten und Zeit eingespart werden. Diese Experten können dann in Erscheinung treten, wenn die vorgeschalteten Instanzen keine Lösung des Problems finden konnten. Außerdem bietet sich die Unterstützung der KI bei gleichen, sich wiederholenden Tätigkeiten wie beispielsweise Wartungs- oder Instandhaltungsaufgaben an. Sie kann Techniker\*innen

unterstützen, bevor ein zertifizierter Prüfer eine Maschine oder Anlage abnimmt. Damit können Techniker\*innen unter anderem ein größeres Aufgabengebiet abdecken. Darüber hinaus können Fehler des Menschen verringert werden. Beim Austausch von Komponenten einer Maschine kann es vorkommen, dass die Mechaniker\*innen Positionen der Montagereihenfolge vergisst, wie zum Beispiel das Anziehen von Schrauben. Die KI erinnert an jede anstehende Tätigkeit und kann bei der Einstellung des Nenndrehmomentes unterstützen, ohne dass Techniker\*innen in Anleitungen oder Auslegungsdaten nachsehen muss.

Als weiterer Anwendungsfall sind einfache automatisierbare Aufgaben wie das Digitalisieren von TZ zu nennen. Wenn ein Unternehmen digital schwach aufgestellt ist, kann die KI helfen, die Zeichnungen oder Stücklisten zu digitalisieren. Die Objekterkennung kann in diesem Fall die in der Zeichnung enthaltenen Bauteile erkennen und die Ausgabe in Form der Text-Datei wird in eine Stückliste übersetzt. Der Mensch müsste im Anschluss an einigen Stellen ergänzend tätig werden; der Großteil der einfachen und eintönigen Arbeit wäre dadurch erledigt.

## 8 Fazit und Ausblick

Laut des Bundesministeriums für Bildung und Forschung bietet die Entwicklung von KI-Systemen große Chancen und Herausforderungen, welche sich auf den Forschungs- und Bildungssektor primär fokussieren sollen [Bun23]. Die vorliegende Arbeit bezieht sich auf beide Teilbereiche, da das Ziel der Entwicklung einer KI-Objekterkennung für TZ und die Konzeptionierung des Einsatzes in der Hochschullehre dies abdecken. Darüber hinaus wurde als Ziel formuliert, das Niveau der KI zu bewerten und mit dem der Studierenden in Bezug auf das Modul Technisches Zeichnen, welches meist im ersten Semester als Grundlagenfach für verschiedene Studiengänge gelehrt wird, zu vergleichen.

In Kapitel 4 wurde eine KI-Objekterkennung für die Bauteilerkennung in TZ entwickelt. Zunächst wurden Vorversuche durchgeführt, um eine effektive Entwicklungsrichtung zu bestimmen. Es wurden wichtige Definitionen von Klassen vorgenommen, die repräsentativ für häufig in TZ vorkommende Objekte sind. In der Voranalyse wurde der Einfluss der Klassen bzw. Merkmale der Klassen, der Trainingsparameter und der Bildgröße (Auflösung) untersucht. Es stellte sich heraus, dass die Erhöhung der Anzahl der Trainingsdaten, eine Neu-Definition der Klassen sowie Bildgröße- und Bildauflösung zweckmäßige Optimierungsansätze darstellen. Es wurde ein automatischer Wellengenerator entwickelt, welcher den Trainingsdatensatz künstlich vergrößern kann. Außerdem wurde die Anzahl der zu berücksichtigenden Objekte verringert, sodass trotzdem verschiedene Objektgrößen und sämtliche Merkmaldichten berücksichtigt werden, damit die Ergebnisse auf weitere Bauteile skalierbar/erweiterbar sind. Das Labeln der Klassen wurde auf eine geringere Fläche lokalisiert, sodass für ein Kugellager beispielsweise zwei Markierungen erstellt werden. Zudem wurde die Hardware in Form des verfügbaren Videospeichers auf 24 GB verbessert, damit mehr Bilder in einem Batch verarbeitet werden können. Die Analyse der Bildgröße hat herausgestellt, dass ein zweistufiger Detektionsalgorithmus die Detektionsqualität deutlich erhöht.

Es wurden drei verschiedene Detektionsmodelle aufgestellt: ein sogenanntes manuelles Modell, welches mit realen Bildern manuell gelabelt und trainiert wurde. Das zweite Modell wurde ausschließlich mit synthetisch durch den automatisierten Wellengenerator erstellten Bilddaten angelernt. Zuletzt wurde ein Modell erstellt, welches reale und synthetische Bilddaten berücksichtigt. Die Auswertung hat ergeben, dass das manuelle Modell mit einer Bildgröße von 800 Pixel sowohl im Training als auch in der Detektion die besten Ergebnisse liefert. Für das Modell wurden die Gewichtungen aus Epoche 150 herangezogen. Trainiert wurde mit einer Anzahl von 400 Bildern, wobei 17 Bilder

pro Batch verarbeitet wurden. Bei der Detektion wurden die Einstellungen für den Vertrauenswert auf 0,4 und für den IoU-Schwellenwert auf 0,5 gesetzt. Damit ergibt sich eine globale Genauigkeit von 0,96. Alle Klassen erreichten eine lokale globale Genauigkeit von mindestens 0,94 bei verschiedenen Konfigurationswerten. Wenn eine Anpassung der Vertrauenswerte an das Optimum der jeweiligen Klassen durchgeführt wird, ist eine durchschnittliche globale Genauigkeit von 0,9925 erreichbar. Diese Anpassung stellt einen mittleren Programmieraufwand dar, wurde innerhalb dieser Arbeit jedoch nicht implementiert. Mit der Erreichung dieser Kennzahlen kann die KI-Detektion als präzise und zuverlässig bewertet werden. Weitere Anpassungen zur Optimierung der Präzision und des GIoU sind jedoch notwendig, um die Lokalisation der Objekte zu verbessern.

Basierend auf dem formulierten Ziel, die Fähigkeit der KI zu bewerten, wurden in Kapitel 5 zunächst die Niveaus, welche zur Erreichung bestimmter Kompetenzen, die für das Modul Technisches Zeichnen wichtig sind, erarbeitet. Zu diesem Zweck wurden Lern- bzw. Kompetenzziele ausformuliert, welche Studierende nach Abschluss des Moduls Technisches Zeichnen erlangt haben sollen. Die Kompetenzziele wurden in Zusammenarbeit mit sechs weiteren Hochschulen des Konsortiums im Rahmen des Projektes *TZ Digital.nrw* verfasst. Sie richten sich nach der Lernzieltaxonomie von Bloom und Anderson. Diese Kompetenzziele wurden mit dem *Constructive Alignment* in Einklang gebracht, sodass die Lernziele mit den Lernaktivitäten und Lernerfolgskontrollen harmonisieren. Die Taxonomiestufen wurden in drei Unterkategorien mit dem fachlichen Anspruch steigend untergliedert: einfach, mittel und schwer. Danach wurden die Lernziele für jedes Thema optimiert und festgehalten, sodass eine objektive Einstufung einer Fähigkeit erfolgen kann.

In Kapitel 6 wurde ein potentiell Anwendungsszenario für die Integration der KI-Detektion in die Lehre dargestellt. Mit Hilfe einer Benutzeroberfläche können Studierende eigene TZ eigenständig und schnell analysieren. Sie erhalten eine Unterstützung bei der Identifikation der Bauteile und erhalten Erklärungen dazu. In dieser Benutzeroberfläche kann ein Bild eingeladen werden, woraufhin die KI-Detektion per Knopfdruck über eine Batch-Datei gestartet wird. Anschließend werden die Detektionen im Bild sowie in Form einer Tabelle mit Erklärungen angezeigt. Innerhalb der Benutzeroberfläche kann *ChatGPT* in einem eigenen Fenster angesteuert werden, falls weitere Informationen benötigt werden. Zuletzt wurde innerhalb des Kapitels diskutiert, wie die KI-Detektion in Bezug auf die im Technischen Zeichnen gelehrt Themen eingebunden werden kann. Es wurden Anwendungsszenarien für die potenzielle Integration in die Lehrveranstaltung des Technischen Zeichnens sowie andere Module aufgezeigt. Demnach bietet es sich an, die KI Detektion mit der VR-Technik zu verknüpfen.

Das siebte und letzte Kapitel befasst sich mit der Analyse und Bewertung des KI-Niveaus. Zunächst wurde eine Punkteskala von 1 bis 10 aufgestellt, um die Fähigkeiten

zu bewerten. Da zehn vorhandene Themen bewertet werden, können 100 Punkte erreicht werden. Insgesamt erreicht die KI-Detektion mit Hilfe von *ChatGPT* 44 Punkte. Zumeist wurde das geringe fachliche Niveau erreicht. Im Vergleich dazu liegt der Punktedurchschnitt von Studierenden bei etwa 70% der zu erreichenden Gesamtpunktzahl. Daraus wurde geschlussfolgert, dass die KI bei einfachen Ingenieur Tätigkeiten und bei der Qualitätskontrolle sowie in der Lehre die Studierenden bei dem Erreichen der Kompetenzen geringen fachlichen Anspruchs unterstützen kann. In Zukunft stellt sich die Frage, wie OER und MOOCs in die Lehre eingebunden werden können. Freiwillig angebotene OER werden kaum genutzt (siehe Anhang E Abbildung E.25(a), Abbildung E.30(a), Abbildung E.35(a), Abbildung E.40(a), Abbildung E.45(a), Abbildung E.50(a), Abbildung E.55(a), Abbildung E.60(a), Abbildung E.65(a) und Abbildung E.70(a)), obwohl die erstellten Lerninhalte durch die Studierenden als verständlich dargestellt, beim Lernen im Semester geholfen, bei der Prüfungsvorbereitung geholfen, passend zur Lehrveranstaltung, medial gut aufbereitet und dargestellt, trägt zum besseren Verständnis bei und sind interaktiv gestaltet bewertet werden. Es sollte untersucht werden, ob die Inhalte durch die Lehrenden genutzt und bearbeitet werden. Das Nutzungsverhalten gibt Aufschluss über die Einbindung der Lehr-/Lerninhalte. Die öffentliche Bereitstellung und Bearbeitbarkeit ist empfehlenswert. Es sollte jedoch überprüft werden, ob der Nutzen den Erstellungsaufwand überwiegt. Durch die geringe Anzahl der Umfrageteilnehmer\*innen ist die Aussagekraft der Evaluation limitiert.

Weiter bietet sich eine Aufbereitung der Inhalte der Module Maschinenelemente als OER an, weil hier ein hoher Überdeckungsgrad der Themenbehandlung und des Umfangs an Hochschulen in NRW vorliegt. In Unterkapitel 6.2.3 wurde gezeigt, dass sich die Themen für die digitale Aufbereitung anbieten. Außerdem eignen sich die Themeninhalte für eine dreidimensionale Aufbereitung sowie für einen Unterstützungsansatz für die KI-Detektion.

In Bezug auf die zukünftige Entwicklung der KI-Detektion sollten weitere Maschinen- und Normteile einbezogen werden, um das Detektionsmodell zu vervollständigen. Die Ergebnisse des ersten Ansatzes deuten darauf hin, dass sich andere Bauteile hinzufügen lassen, ohne die Detektionsqualität erheblich zu beeinflussen. Es sollten auch Trainingsdatensätze aus vielen verschiedenen Kontexten genutzt werden, damit die Detektion robuster und zuverlässiger gegenüber unterschiedlichen TZ ist. Es bietet sich außerdem an, einen Algorithmus zu implementieren, welcher den Vertrauenswert für jede einzelne Klasse an das Optimum anpasst, sodass bei der Detektion verschiedene Werte genutzt werden können. Äußerst interessant ist auch die Nutzung der Option einer Live-Detektion, welche in dieser Arbeit nicht betrachtet wurde, aber mit *YOLO* möglich ist.

Darüber hinaus können die Ergebnisse mit denen neuerer *YOLO*-Versionen verglichen werden, inwiefern eine Verbesserung möglich ist. Außerdem sollte ein zweistufiger Detektor wie zum Beispiel R-CNN entwickelt werden, damit die limitierte Nutzung von *YOLO* optimiert werden kann. In dieser Arbeit findet eine Festlegung der ROI auf Wellenebene statt. Dies ist je nach Anwendung nicht immer optimal oder tauglich. Ein zweistufiger Detektor kann ein effektiveres Festlegen der ROI gewährleisten und den Vergrößerungsfaktor auf das jeweilige Bauteil anpassen, sodass die Detektionsqualität weiter gesteigert wird. Eine Nutzung des zweistufigen Detektors kann auch für andere Anwendungen wie z. B. die Texterkennung ratsam sein (siehe Unterkapitel 2.8).

Digitale Softwarelösungen für die Lehre sind von den Studierenden gewünscht und werden gegenüber haptischen Modellen bevorzugt [Dil22b]. Damit kann das in Kapitel 6 gezeigte Unterstützungstool für Studierende mehr an die Bedürfnisse der Studierenden und Lehrenden angepasst werden, indem spielerische Elementen oder andere Konzepte in die Software integriert werden. Dazu können Spielkonzepte, welche im Stand der Technik beschrieben wurden, für die potenzielle Integration in die Lehrveranstaltungen eingesetzt werden (siehe Unterkapitel 2.5). Ein Gamification-Ansatz mit der Einbindung von spielerischen Elementen wie Highscores oder andere motivierende Bausteine ist für den Lernerfolg förderlich. Diese Aussagen stützt der am Anfang des Projektes *TZ Digital.nrw* ausgeführten Pretests mit 257 Studierenden, die sich eine Aufbereitung in Form von Gamification, 3D-Darstellung oder Digitalisierung wünschen (siehe Anhang D Abbildung D.6). Demnach eignet sich besonders das Thema Normteile für diesen Ansatz. Dies trifft genau auf die in Kapitel 5 entwickelte Software zu. In weiteren Entwicklungsschritten kann die Software als Hilfe für den Konstrukteur ausgearbeitet werden, indem Hinweise zur aktuellen Konstruktion gegeben werden, die auf Normen und Regeln basieren. Ein Beispiel wird wie folgt angeführt: Beachte bei der Sicherungsblechnut einen Durchmesserunterschied der Wellenabsätze von mind. diesem Wert in mm je nach Größe des Wellendurchmessers. Eine Analyse des Bedarfs der Studierenden kann darüber hinaus Entwicklungsziele der Software herausstellen (siehe Unterkapitel 6).

Ein weiterer Ansatzpunkt, welcher in Unterkapitel 6.2.3 angesprochen wurde und sich mit den Anmerkungen von Studierenden deckt, ist die Einbeziehung der VR-Technologie.

In den Umfragen wurde die folgende Aussage getroffen (siehe Anhang D):

*„Anschaffung/Nutzung von 3D-Brillen oder ähnlichen Komponenten zur besseren Veranschaulichung von Praxisbeispielen vor Ort (Universität); mehr Nutzung von digitalen Lösungen mit themenbasierten Aufbau und Transferwissen aus verschiedenen (Bildungs-, Studien-, Wirtschafts-) Bereichen“.*

Dieser Ansatz wird von einigen Lehrenden ebenfalls als vielversprechend angesehen, daher wird das Projekt AssistME in das Leben gerufen, welches sich darauf fokussiert die Bauteile individueller technischer Getriebezeichnungen in zweidimensionaler Form

in eine VR-Umgebung als dreidimensionale Objekte zu übertragen. Damit können die Studierenden ihre eigen konstruierten Getriebe in der virtuellen Umgebung betrachten und damit arbeiten, indem beispielsweise die Bauteile zu einer Gesamtkonstruktion montiert werden. Das Konzept wurde im Jahr 2022 von dem *Deutschen Institut für Virtuelle Realitäten* (DIVR) für die XR-Sciencce Awards in der Kategorie bestes Konzept nominiert [Dil22a].

Am Ende stellt sich die Frage, welche Schritte dafür nötig sind, um Lehrmaterialien als OER für die Öffentlichkeit zugänglich zu machen. Zunächst muss eine der folgenden *Creative Commons* Lizenzen ausgewählt werden: *CC0 1.0*, *CC BY 4.0* oder *CC BY-SA 4.0*. Ein vollständiges Metadatenprofil mit Titel, Urheber\*innen, Lizenz, Link zum Lizenztyp, Ursprungsort (Link zum Original) muss angegeben werden. Die Lehr-/Lernmaterialien sollten qualitätsgesichert sein. Die Materialien werden hierbei durch eine Fachcommunity begutachtet sowie durch eine Evaluation geprüft und optimiert.

# Abbildungsverzeichnis

2.1	Beispielhafte TZ eines Winkelgetriebes . . . . .	3
2.2	Die drei Standbeine des <i>Constructive Alignment</i> . . . . .	7
2.3	Beispielverben für die Einordnung der Lernzieltaxonomie . . . . .	8
2.4	Einordnung der Spielkonzepte . . . . .	9
2.5	Überblick über die Spielekonzeptlandschaft . . . . .	10
2.6	Segmentierung durch Schwellwertbildung . . . . .	12
2.7	Zweidimensionaler Merkmalsraum mit Aktivierungsvektoren . . . . .	12
2.8	Visualisierung zur Berechnung des IoU Wertes . . . . .	14
2.9	Veranschaulichung des GIoU mit Hilfe der Mengenlehre . . . . .	14
2.10	Erkennungsstrategie des Template Matching . . . . .	17
2.11	Ermittlung eines Schlüsselpunktes durch den FAST-Keypoint-Detektor	18
2.12	Bildpyramide als Multiskalendarstellung eines Bildes . . . . .	19
2.13	Aufbau eines neuronalen Netzes . . . . .	21
2.14	Ablauf des <i>YOLO</i> -Algorithmus . . . . .	24
2.15	Unterschied zwischen einstufigen und zweistufigen Detektoren . . . . .	25
2.16	Performancevergleich zwischen den <i>YOLO</i> -Versionen . . . . .	25
2.17	Leistungsvergleich zwischen <i>YOLOv7</i> und <i>YOLOv8</i> . . . . .	26
2.18	KI-Bildererkennung einer TZ mittels Google-Vision . . . . .	27
2.19	Erkennung von Sicherheitsablassventilen in Hydraulikschaltplänen . . .	28
3.1	Vorgehen der Dissertation zur Bestimmung des KI-Niveaus . . . . .	29
4.1	Label des Rillenkugellagers . . . . .	33
4.2	Wellenmutter und Synthese zur Definition der Klasse . . . . .	35
4.3	Gegenüberstellung der gängigen Darstellungsformen des RWDR in TZ .	35
4.4	Einige Label zusammengefasst auf einer Welle . . . . .	36
4.5	Label auf einer Ritzelwelle . . . . .	37
4.6	Label von Wellenmutter und Sicherungsblech . . . . .	38
4.7	Radial außendichtender O-Ring . . . . .	38
4.8	Label des Schrägkugellagers und des Rillenkugellagers . . . . .	39
4.9	Label einer Bohrung . . . . .	40
4.10	Einflussgrößen der Detektionsqualität . . . . .	40
4.11	Verwendete Klassen und Vorkommen der Objekte im Bildraum . . . . .	42
4.12	Verteilung der relativen Objektgröße . . . . .	43
4.13	Werte des Trainings des Vorversuchs . . . . .	43
4.14	Detektionen in einer Getriebezeichnung . . . . .	44
4.15	Generierte Zeichnung des Algorithmus ohne Label mit Störlinien . . . .	47

---

4.16	Neues Label des Schrägkugellagers . . . . .	49
4.17	Neues Label der Wellenmutter . . . . .	50
4.18	Verteilung der Klassen im Training bezüglich Modell 7.08 . . . . .	51
4.19	Trainingsergebnisse zu Modell 7.08 . . . . .	52
4.20	Trainingsergebnisse bezüglich Modell 7.12 . . . . .	52
4.21	Trainingsergebnisse zu Modell 7.12 . . . . .	53
4.22	Trainingsergebnisse zu Modell 7.16 . . . . .	53
4.23	Detektionen an einem synthetischen Datensatz . . . . .	54
4.24	DIN A0 technische Getriebezeichnung . . . . .	55
4.25	Detektionen an der Abtriebswelle . . . . .	56
4.26	Detektionen an der Antriebswelle . . . . .	56
4.27	Abhängigkeit der Erkennungen von der Bildgröße . . . . .	57
4.28	Trainingswerte des zweistufigen manuellen Modells . . . . .	60
4.29	Detektionen an einer Antriebswelle durch das manuelle Modell (I) . . .	61
4.30	Detektionen an einer Antriebswelle durch das manuelle Modell (II) . . .	61
4.31	Diagramm der Qualitätsparameter Verlustrate, Präzision, Recall und globale Genauigkeit . . . . .	63
4.32	Automatisch generierte Zeichnung des angepassten Wellengenerators . .	64
4.33	Trainingswerte zum synthetischen KI-Modell . . . . .	65
4.34	Detektionen des synthetischen Modells . . . . .	66
4.35	Klassenauswertung zum synthetischen Modell . . . . .	67
4.36	Trainingswerte zum gemischten Detektionsmodell . . . . .	69
4.37	Klassenauswertung zum gemischten Modell . . . . .	70
4.38	Klassenauswertung zum gemischten Modell_1200_800 . . . . .	72
4.39	Klassenauswertung zum manuellen Modell_800_1200 . . . . .	73
4.40	Klassenauswertung zum manuellen Modell_1200_800 . . . . .	75
4.41	Klassenauswertung zum manuellen Modell 1200_1200 . . . . .	76
4.42	Klassenauswertung zum Standardmodell mit Vertrauenswert 0,3 . . . .	77
4.43	Klassenauswertung zum Standardmodell mit Vertrauenswert 0,5 . . . .	78
4.44	Klassenauswertung zum Standardmodell mit Vertrauenswert 0,6 . . . .	79
4.45	Klassenauswertung zum Standardmodell mit Vertrauenswert 0,4 und IoU-Schwelle von 0,5 . . . . .	80
4.46	Klassenauswertung zum manuellen Modell mit synthetischen Daten in der Detektion . . . . .	81
4.47	Detektion von synthetisch erstellten Bildern mit dem manuellen Modell	82
4.48	Klassenauswertung zum synthetischen Modell ohne Störgrößen . . . . .	83
4.49	Detektierter RWDR (Normgröße) vs. Nicht detektierter RWDR . . . . .	87
5.1	Anforderungen des <i>Constructive Alignment</i> . . . . .	91
5.2	Aspekte der einführenden Erhebung nach Kerres . . . . .	91

---

5.3	Interaktive Lernlandkarte als Themen- und Inhaltsübersicht . . . . .	94
5.4	TULLU-Regel zur Angabe von Metadaten . . . . .	99
5.5	Einteilung der Komplexitätsstufen . . . . .	100
5.6	Organisationsstruktur der Lehr-/Lerninhalte . . . . .	100
6.1	Übersicht über das entwickelte Unterstützungstool für Studierende . . .	116
6.2	Bildimport und Starten der KI-Detektion . . . . .	117
6.3	Angezeigte Detektion im Bild . . . . .	118
6.4	Dropdown Menü mit Erklärungen zum gefundenen Bauteil . . . . .	119
6.5	Weiter recherchieren mit <i>ChatGPT</i> . . . . .	120
6.6	Beispielhafte Übungsaufgabe aus dem Modul Technisches Zeichnen . .	121
6.7	Detektionen an der Abtriebswelle zur Übungsaufgabe . . . . .	122
6.8	Detektionen an der Antriebswelle zur Übungsaufgabe . . . . .	122
6.9	Beispielhafte Klausuraufgabe im Modul Technisches Zeichnen . . . . .	124
6.10	Erkennungen an der Welle zur beispielhaften Klausuraufgabe . . . . .	125
6.11	Erkennungen an der Bauteilzeichnung zur beispielhafte Klausuraufgabe	126
6.12	Bedarf der Integration von VR . . . . .	132
6.13	Bedarf der Integration von VR II . . . . .	133
6.14	VR-Headset Besitz und Verfügbarkeit . . . . .	133
D.1	Anzahl absolvierter Semester und Erfahrungen zur Klausur . . . . .	183
D.2	Umfang der Lerninhalte . . . . .	183
D.3	Mediendidaktische Aufbereitung . . . . .	184
D.4	Wichtigkeit der Themen aus Sicht der Studierenden . . . . .	184
D.5	Gewichtung der Themen . . . . .	184
D.6	Digitale Aufbereitung . . . . .	185
E.1	Zuordnung zum Studiengang und Semesteranzahl . . . . .	188
E.2	Geschlechterzuordnung und Vorerfahrungen vor dem Studium . . . . .	188
E.3	Meinung und Entwicklung zu OER . . . . .	189
E.4	Einsatz OER und Ergänzung zu vorhandenen Lernmaterialien . . . . .	189
E.5	Bedeutung der Themen Konstruktionsprozess und Erstellen von Frei- handzeichnungen im Studienverlauf . . . . .	189
E.6	Bedeutung der Themen GPS und zielorientierte Bemaßung im Studien- verlauf . . . . .	190
E.7	Bedeutung der Themen Schnitte und Zeichnungsgruppen sowie Normteile und Maschinenelemente im Studienverlauf . . . . .	190
E.8	Bedeutung der Themen Schraubenverbindungen sowie Toleranzen und Passungen im Studienverlauf . . . . .	190
E.9	Bedeutung der Themen Wellenbearbeitung und CAD im Studienverlauf	191
E.10	Bedeutung des Themas Konstruktionsprozess und Umfang des Themas Freihandzeichnungen . . . . .	191

E.11	Bewertung des Umfangs zu den Themen GPS und zielorientierte Bemaßung	191
E.12	Bewertung des Umfangs zu den Themen Schnitte und Zeichnungsgruppen sowie Normteile und Maschinenelemente . . . . .	192
E.13	Bewertung des Umfangs zu den Themen Schraubenverbindungen sowie Toleranzen und Passungen . . . . .	192
E.14	Bewertung des Umfangs zu den Themen Wellenbearbeitung und CAD .	192
E.15	Einschätzung der persönlichen Fähigkeiten zum Thema Konstruktions- prozess . . . . .	193
E.16	Einschätzung der persönlichen Fähigkeiten zum Thema Erstellen von Freihandzeichnungen . . . . .	193
E.17	Einschätzung der persönlichen Fähigkeiten zum Thema GPS . . . . .	193
E.18	Einschätzung der persönlichen Fähigkeiten zum Thema zielorientierte Bemaßung . . . . .	193
E.19	Einschätzung der persönlichen Fähigkeiten zum Thema Schnitte und Zeichnungsgruppen . . . . .	194
E.20	Einschätzung der persönlichen Fähigkeiten zum Thema Normteile und Maschinenelemente . . . . .	194
E.21	Einschätzung der persönlichen Fähigkeiten zum Thema Schraubenver- bindungen . . . . .	194
E.22	Einschätzung der persönlichen Fähigkeiten zum Thema Toleranzen und Passungen . . . . .	194
E.23	Einschätzung der persönlichen Fähigkeiten zum Thema Wellenbearbeitung	195
E.24	Einschätzung der persönlichen Fähigkeiten zum Thema CAD . . . . .	195
E.25	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Konstruktionsprozess . . . . .	195
E.26	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Konstruktionsprozess . . . . .	196
E.27	Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Konstruktionsprozess . . . . .	196
E.28	Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Konstruktionsprozess . . . . .	196
E.29	Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Konstruktionsprozess . . . . .	197
E.30	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Erstellen von Freihandzeichnungen . . .	197
E.31	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Erstellen von Freihandzeichnungen . . . . .	197
E.32	Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Erstellen von Freihandzeichnungen . . . . .	198

---

E.33	Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Erstellen von Freihandzeichnungen . . . . .	198
E.34	Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Erstellen von Freihandzeichnungen . . . . .	198
E.35	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema GPS . . . . .	199
E.36	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema GPS . . . . .	199
E.37	Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema GPS . . . . .	199
E.38	Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema GPS . . . . .	200
E.39	Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema GPS . . . . .	200
E.40	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema zielorientierte Bemaßung . . . . .	200
E.41	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema zielorientierte Bemaßung . . . . .	201
E.42	Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema zielorientierte Bemaßung . . . . .	201
E.43	Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema zielorientierte Bemaßung . . . . .	201
E.44	Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema zielorientierte Bemaßung . . . . .	202
E.45	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Schnitte und Zeichnungsgruppen . . . . .	202
E.46	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Schnitte und Zeichnungsgruppen . . . . .	202
E.47	Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Schnitte und Zeichnungsgruppen . . . . .	203
E.48	Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Schnitte und Zeichnungsgruppen . . . . .	203
E.49	Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Schnitte und Zeichnungsgruppen . . . . .	203
E.50	Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Normteile und Maschinenelemente . . . . .	204
E.51	Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Normteile und Maschinenelemente . . . . .	204

E.52 Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Normteile und Maschinenelemente . . . . .	204
E.53 Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Normteile und Maschinenelemente . . . . .	205
E.54 Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Normteile und Maschinenelemente . . . . .	205
E.55 Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Schraubenverbindungen . . . . .	205
E.56 Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Schraubenverbindungen . . . . .	206
E.57 Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Schraubenverbindungen . . . . .	206
E.58 Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Schraubenverbindungen . . . . .	206
E.59 Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Schraubenverbindungen . . . . .	207
E.60 Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Toleranzen und Passungen . . . . .	207
E.61 Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Toleranzen und Passungen . . . . .	207
E.62 Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Toleranzen und Passungen . . . . .	208
E.63 Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Toleranzen und Passungen . . . . .	208
E.64 Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Toleranzen und Passungen . . . . .	208
E.65 Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Wellenbearbeitung . . . . .	209
E.66 Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Wellenbearbeitung . . . . .	209
E.67 Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Wellenbearbeitung . . . . .	209
E.68 Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Wellenbearbeitung . . . . .	210
E.69 Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Wellenbearbeitung . . . . .	210
E.70 Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema CAD . . . . .	210

E.71 Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema CAD . . . . .	211
E.72 Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema CAD . . . . .	211
E.73 Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema CAD . . . . .	211
E.74 Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema CAD . . . . .	212
E.75 Einbindung OER bezüglich TZ und Mehrwert der OER . . . . .	212
E.76 Wunsch nach zusätzlichen OER . . . . .	212
F.1 Verteilung der SWS an Hochschulen in NRW bzgl. TZ . . . . .	213
F.2 Verteilung der CP/LP an Hochschulen in NRW bzgl. TZ . . . . .	213
F.3 Verteilung des Workloads an Hochschulen in NRW bzgl. TZ . . . . .	214
G.1 Vergleich des Modulumfangs an den verschiedenen Hochschulen in NRW	215
G.2 Art der Prüfungsleistung bzgl. des Moduls ME . . . . .	216
G.3 Verteilung der CP/LP für das Modul Maschinenelemente in NRW . . .	216
G.4 Workload pro Leistungspunkt bzgl. des Moduls ME in NRW . . . . .	217
G.5 Verteilung der SWS pro Semester in NRW in Bezug auf das Modul ME	217
G.6 Vorkommen der Themen im Fach Maschinenelemente an NRW Hochschulen	218

---

# Tabellenverzeichnis

2.1	Wahrheitsmatrix zur Beurteilung der Objekterkennung . . . . .	13
4.1	Definierte Klassen für die Objekterkennung . . . . .	34
4.2	Trainingsparameter der Vorversuche . . . . .	41
4.3	Liste der neu definierten Klassen . . . . .	48
4.4	Versuchsplan zu den Versuchen des zweistufigen Detektors . . . . .	59
4.5	Trainingsdaten zum zweistufigen manuellen Detektionsmodell . . . . .	59
4.6	Wahrheitsmatrix mit den Werten zum manuellen Training . . . . .	62
4.7	Übersicht der für das synthetische Training genutzten Parameter . . . . .	65
4.8	Wahrheitsmatrix zum synthetischen KI-Modell . . . . .	66
4.9	Übersicht der für das gemischte Training genutzten Parameter . . . . .	68
4.10	Wahrheitsmatrix zum gemischten Modell . . . . .	69
4.11	Wahrheitsmatrix zum gemischten Modell 1200 . . . . .	71
4.12	Wahrheitsmatrix zum manuellen Modell 800_1200 . . . . .	73
4.13	Wahrheitsmatrix zum manuellen Modell 1200_800 . . . . .	74
4.14	Wahrheitsmatrix zum manuellen Modell 1200_1200 . . . . .	76
4.15	Tabellarische Darstellung aller Ergebnisse im Durchschnitt . . . . .	85
4.16	Zusammenfassung der erreichten Optima der einzelnen Klassen . . . . .	86
7.1	Vergleich der Punkteverteilung zwischen KI und Studierenden . . . . .	137
C.1	Liste der Hochschulen aus NRW mit TZ-Bezug . . . . .	182

# Literaturverzeichnis

- [3Dr22] 3Druck.com. *Software-Projekt "RAPID" will 2D-Zeichnungen in 3D-Druck-Modelle umwandeln.* (zuletzt geprüft am 18.08.2023), 2022. URL: <https://3druck.com/programme/rapid-2d-zeichnungen-3d-modelle-08107659/>.
- [Aal08] Aalst, W. M. P. van der u. a. *Process mining: a two-step approach to balance between underfitting and overfitting.* *Softw Syst Model* 9, 87–111 (2010), 2008. URL: <https://doi.org/10.1007/s10270-008-0106-z>.
- [Abd13] Abdelhameed, Wael A. *Virtual Reality Use in Architectural Design Studios: A Case of Studying Structure and Construction.* In *Procedia Computer Science*, Vol. 25, pp. 220-230, 2013.
- [Ale18] Ale, Laha; Ning, Zhang Li und Li, Longzhuang. *Road Damage Detection Using RetinaNet.* *IEEE International Conference on Big Data (Big Data)* Seattle, WA, USA, 2018.
- [And94] Anderson, Lorin; Sosniak, Lauren und Bloom, Benjamin. *Bloom's taxonomy : a forty-year retrospective.* University of Chicago press, 1994. URL: <http://lib.ugent.be/catalog/rug01:000925762>.
- [Arn04] Arnold, Patricia; Zimmer, Gerhard M.; Kilian, Lars und Thilloßen, Anne. *E-Learning - Handbuch für Hochschulen und Bildungszentren: Didaktik, Organisation, Qualität.* BW Bildung und Wissen; ISBN: 9783821472355, 2004.
- [Ata23] Atakishiyev, Shahin; Salameh, Mohammad; Yao, Hengshuai und Goebel, Randy. *Explainable Artificial Intelligence for Autonomous Driving: A Comprehensive Overview and Field Guide for Future Research Directions.* (Zuletzt geprüft am 18.08.2023), 2023. URL: <https://arxiv.org/abs/2112.11561>.
- [BK21] Bansal, Monika und Kumar, Manish. *2D object recognition: a comparative analysis of SIFT, SURF and ORB feature descriptors.* *Multimed Tools Appl* 80, 18839–18857 (2021). <https://doi.org/10.1007/s11042-021-10646-0>, 2021.
- [BL20] Basulto-Lantsova, Artiom; Padilla-Medina, Jose; Perez-Pinal und Barranco-Gutierrez, Alejandro. *Performance comparative of OpenCV Template Matching method on Jetson TX2 and Jetson Nano developer kits.* In: *2020 10th Annual Computing, Communication Workshop und Conference (CCWC)*, 2020.

- [Bay06] Bay, Herbert; Tuytelaars, Tinne und Gool, Luc Van. *SURF: Speeded Up Robust Features*. Computer Vision – ECCV 2006, 2006, Volume 3951; ISBN : 978-3-540-33832-1, 2006.
- [Bec21] Becker, Katrin. *What's the difference between gamification, serious games, educational games, and game-based learning?* In: 2771-9359. DOI: 10.20935/AL209, 2021.
- [Bel15] Bell, Sean; Zitnick, C. Lawrence; Bala, Kavita und Girshick, Ross. *Inside-Outside Net: Detecting Objects in Context with Skip Pooling and Recurrent Neural Networks*. (Zuletzt geprüft am 18.08.2023), 2015. URL: <https://doi.org/10.48550/arXiv.1512.04143>.
- [BT11] Biggs, John und Tang, Catherine. *Teaching for quality learning at university: What the student does (4th ed.)* Maidenhead: McGraw-Hill/Society for Research into Higher Education/Open University Press, 2011.
- [BE74] Bloom, Benjamin Samuel und Engelhart, Max. *Taxonomie von Lernzielen im kognitiven Bereich*. Weinheim; Beltz, 1974.
- [Boc20] Bochkovskiy, Alexey; Wan, Chien-Yao und Liao, Hong-Yuan Mark. *YOLOv4: Optimal Speed and Accuracy of Object Detection*. (Zuletzt geprüft am 18.08.2023), 2020. URL: <https://arxiv.org/abs/2004.10934>.
- [BMM16] Borski, Sonja und Muuß-Merholz, Jöran. *OER leichtgemacht mit der TULLU-Regel*. <https://open-educational-resources.de/oer-tullu-regel/> (zuletzt geprüft am 18.08.2023), 2016.
- [BB10] Breuer, Johannes und Bente, Gary. *Why So Serious? On the Relation of Serious Games and Learning*. Eludamos. Journal for Computer Game Culture; DOI: <https://doi.org/10.7557/23.6111>, 2010.
- [Bun22] Bundesministerium, für Bildung und Forschung. *OER-Strategie Freie Bildungsmaterialien für die Entwicklung digitaler Bildung*. 2022. URL: [https://www.bmbf.de/SharedDocs/Publikationen/de/bmbf/3/691288\\_OER-Strategie.pdf?\\_\\_blob=publicationFile&v=6](https://www.bmbf.de/SharedDocs/Publikationen/de/bmbf/3/691288_OER-Strategie.pdf?__blob=publicationFile&v=6).
- [Bun23] Bundesministerium, für Bildung und Forschung. *Künstliche Intelligenz*. 2023. URL: [https://www.bmbf.de/bmbf/de/forschung/digitale-wirtschaft-und-gesellschaft/kuenstliche-intelligenz/kuenstliche-intelligenz\\_node.html](https://www.bmbf.de/bmbf/de/forschung/digitale-wirtschaft-und-gesellschaft/kuenstliche-intelligenz/kuenstliche-intelligenz_node.html).
- [Bun19] Bundesministerium, für Wirtschaft und Klimaschutz. *Einsatz von Künstlicher Intelligenz in der Deutschen Wirtschaft Stand der KI-Nutzung im Jahr 2019*. 2019. URL: [https://www.bmwk.de/Redaktion/DE/Publikationen/Wirtschaft/einsatz-von-ki-deutsche-wirtschaft.pdf?\\_\\_blob=publicationFile&v=8](https://www.bmwk.de/Redaktion/DE/Publikationen/Wirtschaft/einsatz-von-ki-deutsche-wirtschaft.pdf?__blob=publicationFile&v=8).

- [Cha18] Chandan, G; Jain, Ayush; Jain, Harsh und Mohana. *Real Time Object Detection and Tracking Using Deep Learning and OpenCV*. 2018 International Conference on Inventive Research in Computing Applications (ICIRCA), 2018.
- [Cho15] Cho, Junghwan; Lee, Kyewook; Shin, Ellie; Choy, Garry und Do, Synho. *How much data is needed to train a medical image deep learning system to achieve necessary high accuracy?* 2015. URL: <https://arxiv.org/abs/1511.06348>.
- [COC23] COCO, Consortium. *Common Objects in Context*. 2023. URL: <https://cocodataset.org/#home>.
- [CC08] Cord, Matthieu und Cunningham, Pádraig. *Machine Learning Techniques for Multimedia - Case Studies on Organization and Retrieval*. Springer-Verlag Berlin Heidelberg 2008, 2008. URL: <https://doi.org/10.1007/978-3-540-75171-7>.
- [Dao22] Daoud, Eduard; Khalil, Nabil und Gaedke, Martin. *Implementation of a one Stage Object Detection Solution to Detect Counterfeit Products Marked With a Quality Mark*. IADIS International Journal on Computer Science und Information Systems Vol. 17, No. 1, pp. 37-49 ISSN: 1646-3692, 2022.
- [Det11] Deterding, Sebastian; Dixon, Dan; Rilla, Khaled und Nacke, Lennart. *From Game Design Elements to Gamefulness: Defining Gamification*. In: Proceedings of the 15th International Academic MindTrek Conference: Envisioning Future Media Environments, MindTrek 2011, 2011. URL: DOI:10.1145/2181037.2181040.
- [Deu23] Deutsche, Telekom AG. *Manifest zur Nutzung von KI verabschiedet*. (zuletzt geprüft am 18.08.2023), 2023. URL: <https://www.telekom.com/de/konzern/details/telekom-verpflichtet-sich-auf-ki-ethik-1025794>.
- [Deu14] Deutsche, UNESCO-Kommission. *Inklusion: Leitlinien für die Bildungspolitik. Bonn (3. erw. Aufl.)* Deutsche UNESCO-Kommission e.V. (DUK), ISBN: 978-3-940785-55-8, 2014.
- [Deu09] Deutsches, Institut für Normung. *DIN 981*. Deutsches Institut für Normung, 2009.
- [Dil22a] Dillenhöfer, Fabian; Doksanbir, Abdullah; Kraske, Lennart und Künne, Bernd. *AssistME - Unterstützungstool für angehende Ingenieure in der Konstruktion*. XR Science Awards, nominiert für das beste Konzept, 2022.

- [Dil23a] Dillenhöfer, Fabian; Doksanbir, Abdullah; Kraske, Lennart und Künne, Bernd. *Automatic Generation of Training Data for AI Object Detection in terms of Technical Drawings in Engineering*. The International Conference on Remote Engineering und Virtual Instrumentation (REV)01–03 March, 2023 Porto Palace Hotel, Thessaloniki, Greece, 2023.
- [DK22] Dillenhöfer, Fabian und Künne, Bernd. *Analysis of learning objects for optimization and digital transfer - report of intermediate results on learning path ideas*. In: IADIS International Conference e-Learning 2022, S. 169–172, 2022.
- [Dil22b] Dillenhöfer, Fabian; Künne, Bernd und Willms, Ulrike. *Neologised teaching concept and materials combine remote teaching and hands-on activities*. In: 2022 IEEE German Education Conference (GeCon). 2022 IEEE German Education Conference (GeCon), 2022.
- [Dil23b] Dillenhöfer, Fabian u. a. *Development of Modular E-Learning Materials as OER for a MOOC*. In: 17th International Conference on e-Learning und Digital Learning Porto, Portugal 15 – 17 July 2023, 2023.
- [Dil23c] Dillenhöfer, Fabian u. a. *TZ Digital.nrw Digitalisierungsprojekt*. Gefördert durch: Ministry for Culture und Science of the state of North Rhine-Westphalia (MKW) under Grant No. 214-5.01.03.02 - 145504, 2023.
- [Dod18] Dodel, David. *Autonomes Fahren Teil 2*. Formula Student Competition 2018 mit iteratec und municHMotorsport (zuletzt geprüft am 18.08.2023), 2018.
- [Dok23] Doksanbir, Abdullah; Dillenhöfer, Fabian und Künne, Bernd. *Work-in-Progress: A Study on the Problems of Engineering Students Design-ing Gearboxes and VR as a Possible Solution*. 20th International Conference on Remote Engineering und Virtual Instrumentation [unveröffentlicht], 2023.
- [Dzh22] Dzhusupova, Rimma; Banotra, Richa; Bosch, Jan und Olsson, Helena Holmström. *Pattern Recognition Method for Detecting Engineering Errors on Technical Drawings*. In: 2022 IEEE World AI IoT Congress (AIIoT), DOI: 10.1109/AIIoT54504.2022.9817294, 2022.
- [ELI23] ELIAS, GmbH. *Auf einen Blick*. (zuletzt geprüft am 18.08.2023), 2023. URL: <https://www.elias-gmbh.de/de/>.
- [Ely20] Elyan, Eyad; Jamieson, Laura und Ali-Gombe, Adamu. *Deep learning for symbols detection and classification in engineering drawings*. Neural Networks Volume 129, September 2020, Pages 91-102, 2020.

- [Erh08] Erhardt, Angelika. *Einführung in die Digitale Bildverarbeitung Grundlagen, Systeme und Anwendungen*. Vieweg+Teubner Verlag Wiesbaden, <https://doi.org/10.1007/978-3-8348-9518-9>, 2008.
- [Faw06] Fawcett, Tom. *An introduction to ROC analysis*. In: Pattern Recognition Letters 27 (8), S. 861–874. DOI: 10.1016/j.patrec.2005.10.010, 2006.
- [Fir20] Firas, Ouerghi. *AI for technical drawings*. Master Thesis University Of Tunis El-Manar, 2020.
- [Fla16] Flasiński, Mariusz. *Introduction to artificial intelligence*. Springer, 2016.
- [Fro18] Frochte, Jörg. *Maschinelles Lernen: Grundlagen und Algorithmen in Python*. Hanser eLibrary. München: Hanser, 2018, 2018.
- [Goo23] Google, Developers. *Machine Learning Glossary*. 2023. URL: <https://developers.google.com/machine-learning/glossary#m>.
- [Hah12] Hahne, Markus. *Entwicklung eines Prozessmodells der Interpretation Technischer Zeichnungen*. Deutsche Nationalbibliothek, 2012.
- [Has16] Hashemi, Nazanin Sadat; Aghdam, Roya Babaie; Ghiasi, Atieh Sadat Bayat und Fatemi, Parastoo. *Template Matching Advances and Applications in Image Analysis*. American Scientific Research Journal for Engineering, Technology, und Sciences (ASRJETS), 2016. URL: <https://arxiv.org/abs/1610.07231>.
- [Hob14] Hoblitz, Anna. *Spielend Lernen im Flow*. Wiesbaden: Springer VS (2015), VIII, 2014.
- [Hua18] Huang, Jingjin; Zhou, Guoqing; Zhou, Xiang und Zhang, Rongting. *A New FPGA Architecture of FAST and BRIEF Algorithm for On-Board Corner Detection and Matching*. Sensors 2018, 18, 1014, 2018. URL: <https://doi.org/10.3390/s18041014>.
- [HH12] HuotariJuho, Kai und Hamari, HamariJuho. *Defining Gamification - A Service Marketing Perspective*. Conference: 16th International Academic Mindtrek Conference, DOI: 10.1145/2393132.2393137, 2012.
- [Jä12] Jähne, Bernd. *Digitale Bildverarbeitung und Bildgewinnung*. Springer Berlin, Heidelberg, <https://doi.org/10.1007/978-3-642-04952-1>, 2012.
- [Joc23] Jocher, Glenn; Chaurasia, A. und Qiu, J. *YOLO by Ultralytics (Version 8.0.0)*. GITHUB, <https://github.com/ultralytics/ultralytics> (zuletzt geprüft am 18.08.2023), 2023.
- [Joh16] Johnson, Larry u. a. *NMC Horizon Report: 2016 Higher Education Edition*. The New Media Consortium, 2016.

- [Kap17] Kaplan, Jerry. *Künstliche Intelligenz: Eine Einführung*. mitp-Verlag, ISBN: 9783958456327, 2017.
- [Ker18] Kerres, Michael. *Mediendidaktik. Konzeption und Entwicklung digitaler Lernangebote*. 5. Auflage. De Gruyter Oldenbourg (De Gruyter Studium), 2018.
- [Kü16] Künne, Bernd. *Maschinenelemente kompakt. Band 1: Technisches Zeichnen*. Soest: Maschinenelemente-Verlag, 2016.
- [Kü23] Künne, Bernd. *Klausurergebnis zum Modul Technisches Zeichnen [interne Quelle unveröffentlicht]*. Fachgebiet Maschinenelemente, 2023.
- [KW19] Künne, Bernd und Willms, Ulrike. *Maschinenelemente kompakt. Band 2: Gestaltung*. Soest: Maschinenelemente-Verlag, 2019.
- [KT08] Koutroumbas, Konstantinos und Theodoridis, Sergios. *Pattern Recognition*. Academic Press, Elsevier, 2008.
- [Kra22] Kraske, Jan Lennart. *Entwicklung eines Programms zur automatisierten Erstellung von wellenbasierten Trainingsdaten für einen KI-Objekterkennungsalgorithmus um Maschinenelemente in technischen Zeichnungen zu erkennen*. Masterarbeit, Fachgebiet Maschinenelemente, TU Dortmund [unveröffentlicht], 2022.
- [Kre22] Kremenetsky, Matt. *French DARPA to Drive Automated 2D-to-3D 3D Printing Software*. <https://3dprint.com/290583/french-darpa-to-drive-automated-2d-to-3d-3d-printing-software/> (zuletzt geprüft am 18.08.2023), 2022.
- [Lei04] Leibe, Bastian; Leonardis, Ales und Schiele, Bernt. *Combined Object Categorization and Segmentation with an Implicit Shape Model*. in ECCV'04 Workshop on Statistical Learning in Computer Vision, Prague, May 2004, 2004.
- [Lew15] Lewontin, Max. *Open AI: Effort to democratize artificial intelligence research?* (zuletzt geprüft am 18.08.2023), 2015. URL: <https://www.csmonitor.com/Technology/2015/1214/Open-AI-Effort-to-democratize-artificial-intelligence-research>.
- [Lin17] Lin, Tsung-Yi; Goyal, Priya; Girshick, Ross; He, Kaiming und Dollár, Piotr. *Focal Loss for Dense Object Detection*. (zuletzt geprüft am 18.08.2023), 2017. URL: <http://arxiv.org/abs/1708.02002>.
- [Lin14] Lin, Tsung-Yi u. a. *Microsoft COCO: Common Objects in Context*. Computer Vision – ECCV 2014. ECCV 2014. Lecture Notes in Computer Science, vol 8693. Springer, Cham., 2014.

- [Lin12] Lindeberg, Tony. *Scale Invariant Feature Transform*. In: ScholarpediaChapter: 7(5):10491, 2012. URL: [http://www.scholarpedia.org/article/Scale\\_Invariant\\_Feature\\_Transform](http://www.scholarpedia.org/article/Scale_Invariant_Feature_Transform).
- [Lz09] Liu, Ling und Özsu, M. Tamer. *Encyclopedia of database systems*. New York, NY: Springer, 2009, 2009.
- [Low04] Lowe, David G. *Distinctive Image Features from Scale-Invariant Keypoints*. International Journal of Computer Vision 60, 91–110, 2004. URL: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>.
- [Lun10] Lunze, Jan. *Künstliche Intelligenz für Ingenieure. 2. Auflage*. München: Oldenbourg, 2010.
- [Lun16] Lunze, Jan. *Künstliche Intelligenz für Ingenieure. Methoden zur Lösung ingenieurtechnischer Probleme mit Hilfe von Regeln, logischen Formeln und Bayesnetzen. 3., überarbeitete Auflage*. Berlin, Boston: De Gruyter Oldenbourg, 2016.
- [Maa22] Maatuk, Abdelsalam M.; Elberkawi, Ebitisam K.; Aljawarneh, Shadi; Ras-haideh, Hasan und Alharbi, Hadeel. *The COVID-19 pandemic and E-learning: challenges and opportunities from the perspective of students and instructors*. Journal of Computing in Higher Education, 2022. URL: <https://doi.org/10.1007/s12528-021-09274-2>.
- [Mal23] Mallick, Satya. *YOLOv8 Ultralytics: State-of-the-Art YOLO Models*. (zuletzt geprüft am 18.08.2023), 2023. URL: <https://learnopencv.com/ultralytics-yolov8/>.
- [May09] Mayer, Horst. *Planung und Überprüfung von Lernzielen*. 2009. URL: [http://www.e-learning2009.de/media/Workshop-Band\\_Delfi.pdf](http://www.e-learning2009.de/media/Workshop-Band_Delfi.pdf).
- [Mei17] Meinel, Christoph. *Eine Vision für die Zukunft digitaler Bildung*. In: Frankfurter Allgemeine Zeitung, 20.04.2017, S. 20–21, 2017.
- [Met11] Metraglia, Riccardo; Baronio, Gabriele und Villa, Valerio. *Learning levels in technical drawing education: proposal for an assessment grid based on the European Qualifications Framework (EQF)*. In: Proceedings of the 18th International Conference on Engineering Design (ICED 11), Impacting Society through Engineering Design, Vol. 8: Design EducationPublisher: Design SocietyEditors: S.J. Culley u. a., 2011.
- [Mü20] Müller, Patrik; Gembarsk, Paul Christoph und Lachmayer, Roland. *Detektion von Konstruktionsfehlern durch eine automatisierte Objekterkennung mittels Deep Learning*. Conference: 18. Gemeinsames Kolloquium KonstruktionstechnikAt: Duisburg, 2020.

- [Mru20] Mrutyunjay, Anuroop; Kondrakunta, Pragnya und Rallapalli, Hemalatha. *Non-max Suppression for Real-Time Human Localization in Long Wavelength Infrared Region*. In: Suresh Chandra Satapathy (Hg.): *Advances in Decision Sciences, Image Processing, Security, Computer Vision*. International Conference on Emerging Trends in Engineering (ICETE), Vol. 2, Bd. 4. Unter Mitarbeit von K. Srujan Raju, K. Shyamala, D. Rama Krishna und Margarita N. Favorskaya. Cham: Springer International Publishing AG (Learning und Analytics in Intelligent Systems Ser, v.4), S. 166-174, 2020.
- [Mur13] Murray, Joddy. *Composing Multimodality*. In: *Multimodal Composition: A Critical Sourcebook*. Bedford/St. Martin's, 2013.
- [Nai14] Naik, Nitin. *A comparative evaluation of game-based learning: Digital or non-digital games?* Proceedings of the European Conference on Games-based Learning, ISBN: 9781910309551, 2014.
- [NE22] Niggemann, Oliver und Elmers, Miriam. *Künstliche Intelligenz in Produktion und Maschinenbau. Hintergründe, Anwendungsszenarien, Expertentipps*. Berlin, Offenbach: VDE VERLAG GMBH, 2022.
- [Nis20] Nischwitz, Alfred; Fischer, Max; Haberäcker, Peter und Socher, Gudrun. *Bildverarbeitung Band II des Standardwerks Computergrafik und Bildverarbeitung*. Springer Vieweg Wiesbaden, 2020. URL: <https://doi.org/10.1007/978-3-658-28705-4>.
- [Now19] Nowruzi, Farzan Erlik u. a. *How much real data do we actually need: Analyzing object detection performance using synthetic and real data*. <https://arxiv.org/pdf/1907.07061> (zuletzt geprüft am 18.08.2023), 2019.
- [OPE23a] OPEN, AI. *GPT-4 Technical Report*. 2023. URL: <https://chat.openai.com/auth/login>.
- [OPE23b] OPEN, AI. *GPT-4 Technical Report*. 2023. URL: <https://arxiv.org/pdf/2303.08774.pdf>.
- [Ope22] OpenCV. *ORB (Oriented FAST and Rotated BRIEF)*. (zuletzt geprüft am 18.08.2023), 2022. URL: [https://docs.opencv.org/3.4/d1/d89/tutorial\\_py\\_orb.html](https://docs.opencv.org/3.4/d1/d89/tutorial_py_orb.html).
- [Ope23] OpenCV. *ORB (Oriented FAST and Rotated BRIEF)*. (zuletzt geprüft am 18.08.2023), 2023. URL: [https://docs.opencv.org/3.4/d1/d89/tutorial\\_py\\_orb.html](https://docs.opencv.org/3.4/d1/d89/tutorial_py_orb.html).
- [ORC22] ORCA.nrw, Feikens. *Handreichung OER@ORCA.nrw, 2. Ausgabe*. Geschäftsstelle des Landesportals ORCA.nrw, 2022.

- [Ott11] Ott, Bernd. *Grundlagen des beruflichen Lernens und Lehrens. Ganzheitliches Lernen in der beruflichen Bildung*. Berlin: Cornelsen Girarde, 2011.
- [Pad23] Padilla, Rafael; Netto, Sergio L. und Silva, Eduardo A. B da. *A Survey on Performance Metrics for Object-Detection Algorithms*. 2020 International Conference on Systems, Signals und Image Processing (IWSSIP), 2023. URL: <https://ieeexplore.ieee.org/document/9145130>.
- [Pan09] Pantelidis, Veronica S. *Reasons to Use Virtual Reality in Education and Training Courses and a Model to Determine When to Use Virtual Reality*. THEMES IN SCIENCE und TECHNOLOGY EDUCATIONSpecial Issue, Pages 59-70Klidarithmos Computer Books, 2009.
- [Pa22] Pelanis, Egidijus und al., et. *Use of mixed reality for improved spatial understanding of liver anatomy*. Minim Invasive Ther Allied Technol. 2020 Jun;29(3):154-160. doi: 10.1080/13645706.2019.1616558, 2022.
- [Pet06] Peterßen, Wilhelm H. *Handbuch Unterrichtsplanung. Grundfragen, Modelle, Stufen, Dimensionen. 9., aktualisierte und überarb. Aufl.* München: Oldenbourg, 2006.
- [Pic21] Picciano, Anthony G.; Dziuban, Charles D.; Graham, Charles R. und Moskal, Patsy D. *Blended Learning Research Perspectives, Volume 3*. New York Routledge, <https://doi.org/10.4324/9781003037736>, 2021.
- [Pop11] Popescu, Maria u. a. *Serious Games in Formal Education: Discussing Some Critical Aspects*. 5th European Conference on Game based Learning, 2011.
- [Pre01] Prensky, Marc. *Digital Game-Based Learning*. McGraw-Hill, 2001.
- [Red15] Redmon, Joseph; Divvala, Santosh; Girshick, Ross und Farhadi, Ali. *You Only Look Once: Unified, Real-Time Object Detection*. 2016 IEEE Conference on Computer Vision und Pattern Recognition (CVPR), DOI: 10.1109/CVPR.2016.91, 2015.
- [RR03] Reinmann-Rothmeier, Gabi; Vohle, Frank; Adler, Frederic und Faust, Heidi. *Didaktische Innovation durch Blended Learning. Leitlinien anhand eines Bei-spiels aus der Hochschule*. Bern (Schweiz): Hans Huber, 2003.
- [Rei15] Reitmaier, Tobias. *Aktives Lernen für Klassifikationsprobleme unter der Nutzung von Strukturin-formationen*. Gesellschaft für Informatik, 2015.
- [Rez19] Rezatofighi, Hamid u. a. *Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression*. 2019 IEEE/CVF Conference on Computer Vision und Pattern Recognition (CVPR), 2019.
- [Rit09] Ritterfeld, Ute; Cody, Michael und Vorderer, Peter. *Serious Games. Mechanisms and Effects. 1st ed.* London: Routledge, 2009.

- [Rub11] Rublee, Ethan; Rabaud, Vincent; Konolige, Kurt und Bradski, Gary. *ORB: an efficient alternative to SIFT or SURF*. 2011 International Conference on Computer Vision, Barcelona, Spain, 2011. URL: doi:10.1109/ICCV.2011.6126544.
- [Rus15] Russakovsky, Olga u. a. *ImageNet Large Scale Visual Recognition Challenge*. ImageNet Large Scale Visual Recognition Challenge. Int J Comput Vis 115, 211–252 (2015). <https://doi.org/10.1007/s11263-015-0816-y>, 2015.
- [SA21] Sabouret, Nicolas und Assis, Lizete de. *Understanding Artificial Intelligence*. Boca Raton, FL, London, New York: CRC Press (A Chapman & Hall Book), 2021.
- [Sar21] Sarda, Abhishek; Dixit, Shubhra und Bhan, Anupama. *Object Detection for Autonomous Driving using YOLO algorithm*. 2021 2nd International Conference on Intelligent Engineering und Management (ICIEM), London, United Kingdom, doi: 10.1109/ICIEM51511.2021.9445365, 2021.
- [SM07] Sawyer, Keith und Marosz, Jonathan. *Group Genius: The Creative Power of Collaboration*. New York: Basic Books, 2007.
- [SK03] Schnabel, Marc A. und Kvan, Thomas. *Spatial Understanding in Immersive Virtual Environments*. International Journal of Architectural Computing. 2003;1(4):435-448. doi:10.1260/147807703773633455, 2003.
- [Sch21] Schröder, Marvin. *Konstruktionsprojekt*. Fachgebiet Maschinenelemente [unveröffentlicht], 2021.
- [SB07] Schuchardt, Philip und Bowman, Doug A. *The benefits of immersion for spatial understanding of complex underground cave systems*. In: Proceedings of the 2007 ACM symposium on Virtual reality software und technology (VRST '07). Association for Computing Machinery, New York, NY, USA, 2007. URL: <https://doi.org/10.1145/1315184.1315205>.
- [Sch13] Schulmeister, Rolf. *MOOCs – Massive Open Online Courses: Offene Bildung oder Geschäftsmodell?* Münster: Waxmann, 2013.
- [Sha20] Shahinfar, Saleh; Meek, Paul und Falzon, Greg. *“How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring*. 2020. URL: <https://doi.org/10.1016/j.ecoinf.2020.101085>.
- [TZ04] Tekinbaş, Katie Salen und Zimmerman, Eric. *Rules of Play Game Design Fundamentals*. The MIT Press, 2004.

- [Tya19] Tyagi, Deepanshu. *Introduction to ORB (Oriented FAST and Rotated BRIEF)*. <https://medium.com/data-breach/introduction-to-orb-oriented-fast-and-rotated-brief-4220e8ec40cf> (zuletzt geprüft am 18.08.2023), 2019.
- [UNE02] UNESCO. *Forum on the impact of Open Courseware for higher education in developing countries (Final report)*. Paris: UNESCO (zuletzt geprüft am 18.08.2023), 2002. URL: <http://unesdoc.unesco.org/images/0012/001285/128515e.pdf>.
- [UNE19] UNESCO. *Open Educational Resources*. UNESCO (zuletzt geprüft am 18.08.2023), 2019. URL: <https://www.unesco.org/en/open-educational-resources>.
- [Vor19] Voronina, Marianna V.; Tretyakova, Zlata O.; Krivonozhkina, Ekaterina G.; Buslaev, Stanislav I. und Sidorenko, Grigory G. *Augmented Reality in Teaching Descriptive Geometry, Engineering and Computer Graphics – Systematic Review and Results of the Russian Teachers’ Experience*. EURASIA J Math Sci Tech Ed, Volume 15, Issue 12, 2019.
- [W2421] W24, Service GmbH. *Beyond OCR - Using AI to Understand Complex Technical Drawings. Feature Extraction from Technical Drawings*. (zuletzt geprüft am 18.08.2023), 2021. URL: <https://werk24.io/blog/beyond-ocr-using-ai-to-understand-complex-technical-drawings>.
- [Wan21] Wang, Chien-Yao; Bochkovskiy, Alexey und Liao, Hong-Yuan Mark. *Scaled-YOLOv4: Scaling Cross Stage Partial Network*. 2021 IEEE/CVF Conference on Computer Vision und Pattern Recognition (CVPR), 2021.
- [Wan22] Wang, Chien-Yao; Bochkovskiy, Alexey und Liao, Hong-Yuan Mark. *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. DOI: 10.48550/arXiv.2207.02696 (zuletzt geprüft am 18.08.2023), 2022. URL: <https://arxiv.org/pdf/2207.02696>.
- [Wan20] Wang, Chien-Yao u. a. *CSPNet: A New Backbone that can Enhance Learning Capability of CNN*. 2020 IEEE/CVF Conference on Computer Vision und Pattern Recognition Workshops (CVPRW), 2020.
- [WR14] Warwitz, Siegbert A. und Rudolf, Anita. *Vom Sinn des Spielens. Reflexionen und Spielideen. 3., aktualisierte Aufl.* Baltmannsweiler: Schneider-Verl. Hohengehren, 2014.
- [Wer21] Werner, Martin. *Digitale Bildverarbeitung Grundkurs mit neuronalen Netzen und MATLAB-Praktikum*. Springer Vieweg Wiesbaden, 2021. URL: <https://doi.org/10.1007/978-3-658-22185-0>.

- [Wha22] WhatIs.com. *What is FLOPS (floating-point operations per second)? / Definition from Tech-Target.* (zuletzt geprüft am 18.08.2023), 2022. URL: <https://www.techtarget.com/whatis/definition/FLOPS-floating-point-operations-per-second>.
- [WI12] Wiley, David und III, John Levi Hilton. *Defining OER-Enabled Pedagogy.* The International Review of Research in Open und Distributed Learning, 19(4), 2012. URL: <https://doi.org/10.19173/irrodl.v19i4.3601>.
- [WW10] Wilson, Scott und Williams, Leslie. *Serious Games for the Classroom.* International Journal of Architectural Computing. 2003;1(4):435-448., 2010. URL: [doi:10.1260/147807703773633455](https://doi.org/10.1260/147807703773633455).
- [Wü21] Würz, Udo. *Das Training durchführen: YOLO Modelle selber trainieren, Folge 3; Fujitsu.* (zuletzt geprüft am 18.08.2023), 2021. URL: [https://www.youtube.com/watch?v=-r6b4ewVxBc&ab\\_channel=UdoW%C3%BCrtz](https://www.youtube.com/watch?v=-r6b4ewVxBc&ab_channel=UdoW%C3%BCrtz).
- [YB10] Yannuzzi, Thomas J. und Behrenshausen, Bryan G. *Serious Games for Transformative Learning.* IGI Global (Interdisciplinary Models und Tools for Serious Games), 2010.
- [Yin19] Ying, Xue. *An Overview of Overfitting and its Solutions.* Journal of Physics: Conference Series, Volume 1168, Issue 2, 2019.
- [Zha20] Zhao, Yunfan; Deng, Xueyuan und Lai, Huahui. *A Deep Learning-Based Method to Detect Components from Scanned Structural Drawings for Reconstructing 3D Models.* Applied Sciences. 2020; 10(6):2066., 2020. URL: <https://doi.org/10.3390/app10062066>.
- [ZC11] Zichermann, Gabe und Cunningham, Christopher. *Gamification by Design: Implementing Game Mechanics in Web and Mobile Apps.* Sebastopol, CA: O'Reilly Media, 2011.
- [Zur92] Zurada, Jacek M. *Introduction to artificial neural systems.* (zuletzt geprüft am 18.08.2023), 1992. URL: <https://api.semanticscholar.org/CorpusID:60602644>.
- [Zyd05] Zyda, Michael. *From visual simulation to virtual reality to games.* In: Computer vol. 38, no. 9, pp. 25-32, 2005. URL: <https://ieeexplore.ieee.org/document/1510565>.

# A Batch Datei zum Ausführen der KI-Detektion

```
1 @echo OFF
2 rem Festlegen des Pfades zur Conda Installation
3 set CONDA_PATH=C:\ProgramData\Anaconda3
4
5 rem Definition des Umgebungsnamens
6 set ENVNAME=yolov4
7
8 rem Aktivierung der Base-Umgebung
9 rem call C:\ProgramData\Miniconda3\Scripts\activate.bat C:\
   ProgramData\Anaconda3
10 if yolov4==base (set ENVPATH=C:\Users\kraske\.conda\envs)
   else (set ENVPATH=C:\Users\kraske\.conda\envs\yolov4)
11
12 rem Aufrufen von Anaconda
13 call C:\ProgramData\Anaconda3\Scripts\activate.bat C:\Users\
   kraske\.conda\envs\yolov4
14
15 rem Detektion durch die KI ueber Python mit den verfuegbaren
   Parameterangaben
16 cd C:\Users\dillenhofer\Documents\Yolov4
17 python detect.py --img 800 --conf 0.6 --device 0 --save-txt
   --source data\Dissgui\ --weights weights\
   Modell_Schnitt_erkennung.pt --view-img
18
19 rem Umgebung wird deaktiviert
20 call conda deactivate
```

## B Quellcode für das Unterstützungstool in Python mit Pycharm

```
1 import shutil
2 import tkinter as tk
3 from tkinter import ttk
4 # from PIL import Image, ImageTk
5 from PIL import ImageTk
6 import PIL.Image
7 # import tkMessageBox
8 from tkinter import *
9 from tkinter import messagebox, filedialog
10 import subprocess
11 import webview
12
13 folge=[]
14 zahl = 0
15
16 #Funktionen zum Anzeigen des Detektionsbildes
17 class Picture:
18     def __init__(self, parent):
19         self.parent = parent
20         img = PhotoImage(file='leeres_image.png')
21         self.label = ttk.Label(self.parent)
22         self.label['image'] = img
23         img.image = img
24         self.label.place(x=100*resfacwidth, y=300*resfacheight)
25         btn = Button(self.parent, command=self.update, text='Show
           Detection(s)').place(x=1325*resfacwidth,
26 y=150*resfacheight, height=resize_50, width=resize_150)
27
28     def update(self):
29         resize_image()
30         legearrayan()
31         varia = len(folge)
32         list_box.delete(0, varia)
```

```
33 listboxkonfig ()
34 img = PhotoImage( file='C:/Users/dillenhoefer/Documents/Yolov4/
    inference/output/detectedimage_resized.png')
35 self.label['image'] = img
36 img.image = img
37
38 #Funktion zur Verknuepfung der Listeneintraege an detektierten
    Klasen und den Erklaerungen zu den Bauteilen
39 def weitereinformationen():
40     aktuell_ausgewaehlt = lbox.curselection()
41     textausgabe = ttk.Label(root, text=aktuell_ausgewaehlt)
42     textausgabe.place(x=1250*resfacwidth, y=850*resfacheight)
43     label7 = ttk.Label(root, text="Weitere Informationen")
44     label7.place(x=1350*resfacwidth, y=850*resfacheight)
45
46 #Funktionen zum Anzeigen einer Liste der detektierten Klassen
47 def listboxkonfig():
48     x = len(folge)
49     for d in range(0, x):
50         list_box.insert(d, folge[d])
51         list_box.place(x=1250*resfacwidth, y=350*resfacheight, width
            =300*resfacwidth, height=300*resfacheight)
52         entry1.place(x=1250*resfacwidth, y=675*resfacheight)
53
54 Funktion zum Anzeigen der Erklaerungen zu den Bauteilen
55 def insert_into_entry(Event = None):
56     ndex = list_box.curselection()
57     if ndex != ():
58         selected_item = list_box.get(ndex)
59         entry1.delete(0,END)
60         entry1.insert(END,selected_item)
61         if selected_item == 'Distanzbuchse':
62             label10 = ttk.Label(root, text="Eine Distanzbuchse ist ein
                zylindrisches Objekt (Ring),\nwelcher Abstaende
                ueberbruecken und Kraefte uebertragen kann.")
63             label10.place(x=1250*resfacwidth, y=700*resfacheight, width
                =700*resfacwidth, height=250*resfacheight)
64             label10.configure(font=("Arial", resize_10))
65         elif selected_item == 'Radialwellendichtring':
```

```

66 label11 = ttk.Label(root , text="Radialwellendichtringe sind
    die Standarddichtungen gegen Oelverlust bei rotierenden \
    nTeilen (Wellen). Sie werden im Gehaeuse eingepresst und
    schleifen auf der Welle mit \neiner schmalen und daher
    empfindlichen Dichtkante. Der Standardwerkstoff ist NBR. \
    nNeben der Standardform A gibt es die Form AS mit
    zusaetzlicher Schutzlippe. \nDie Gehaeusebohrung ist mit H8
    zu tolerieren. Als Toleranz des Wellenabsatzes genuegt \
    nh11, jedoch muss die Oberflaeche drallfrei geschliffen mit
    Rz 1 sein; ausserdem benoetigt \nsie eine Mindesthaerte
    von 45 HRC (besser 55 HRC); die Welle sollte also gehaertet
    sein. \nDie normgerechte Bezeichnung lautet:
    Radialwellendichtring DIN 3760 A d1 x d2 x b – NBR,\nalso z
    . B. Radialwellendichtring DIN 3760 A 35 x 55 x 7 – NBR.\n(
    Quelle: Kuenne, B. (2016): Maschinenelemente kompakt. Band
    1: Technisches Zeichnen.\n1. Auflage. 3. Auflage. Soest:
    Maschinenelemente–Verlag.) ")
67 label11.place(x=1250*resfacwidth , y=700*resfacheight , width
    =700*resfacwidth , height=250*resfacheight)
68 label11.configure(font=("Arial" , resize_10))
69 elif selected_item == 'Schraegkugellager ':
70 label12 = ttk.Label(root , text="Schraegkugellager sind in DIN
    628 genormt. Diese koennen Radial– und Axialkraefte \
    nuebertragen und werden haeufig in Trag– Stuetzlagerungen
    verwendet.\n(Quelle: Kuenne, B. (2016): Maschinenelemente
    kompakt. Band 1: Technisches Zeichnen.\n1. Auflage. 3.
    Auflage. Soest: Maschinenelemente–Verlag.")
71 label12.place(x=1250*resfacwidth , y=700*resfacheight , width
    =700*resfacwidth , height=250*resfacheight)
72 label12.configure(font=("Arial" , resize_10))
73 elif selected_item == 'Wellenmutter ':
74 label13 = ttk.Label(root , text="Wellenmuttern DIN 981 mit
    Feingewinde werden zur Festlegung von Lagern und sonstigen\
    nBauteilen auf Wellen verwendet. Sie werden mit
    Sicherungsblechen DIN 5406 dadurch\ngesichert , dass die
    Nase des Sicherungsblechs in eine Nut in der Welle
    eingreift und einer\nder aeusseren Lappen in eine Nut der
    Wellenmutter umgebogen wird. Die normgerechte\nBezeichnung
    lautet beispielsweise Wellenmutter DIN 981 – KM 18.\n(

```

```

Quelle: Kuenne, B. (2016): Maschinenelemente kompakt. Band
1: Technisches Zeichnen.\n1. Auflage. 3. Auflage. Soest:
Maschinenelemente-Verlag.")
75 label13.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
76 label13.configure(font=("Arial", resize_10))
77 elif selected_item == 'Freistich':
78 label14 = ttk.Label(root, text="Freistiche nach DIN 509 werden
    als Bearbeitungsauslaeufe bei Passflaechen genutzt. Form F
    \nfuer die Anlage von Bauteilen auf der Passflaeche und an
    einer axialen Anlageflaeche wird\nam haeufigsten benoetigt;
    Form H kann ebenso verwendet werden, wobei die Herstellung
    \nmittels Wendeschneidplatten einfacher ist. Form E ist bei
    nur einer Passflaeche einsetzbar\nund wird kaum benoetigt.
    Form G ist mit Wendeschneidplatten herstellbar, ist
    platzsparender,\nhat aber eine groessere Kerbwirkung.
    Darstellung s. Kap. 5.6; normgerechte Bezeichnung der\
    ngaengigsten Freistiche (fuer Durchmesser 18 bis
    Durchmesser 80) Freistich DIN 509 – F 0,8 x 0,3\nbzw.
    Freistich DIN 509 – H 0,8 x 0,3, ueber Durchmesser 80
    Freistich DIN 509 – F 1,2 x 0,3.\n(Quelle: Kuenne, B.
    (2016): Maschinenelemente kompakt. Band 1: Technisches
    Zeichnen.\n1. Auflage. 3. Auflage. Soest: Maschinenelemente
    -Verlag.")
79 label14.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
80 label14.configure(font=("Arial", resize_10))
81 elif selected_item == 'Fase':
82 label15 = ttk.Label(root, text="Als Fase bezeichnet man eine
    schraege Kante an Werkstuecken, bei denen man eine scharfe\
    nKante sowohl aus optischen als auch praktischen Gruenden,
    oder zum Vermeiden von\nVerletzungen, entfernt. Dies nennt
    man fachsprachlich dann die Kante "brechen" oder\nauch
    entgraten. Bei Wellen werden Fasen auch fuer die
    Montierbarkeit eingesetzt.\n(Quelle: https://www.mbcad.de/
    glossar/fase/)")
83 label15.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
84 label15.configure(font=("Arial", resize_10))

```

```
85 elif selected_item == 'Sicherungsring':
86 label16 = ttk.Label(root, text="Sicherungsringe fuer Wellen
    sind in DIN 471 genormt. Ringgroesse und Ringdicke richten\
    nsich nach dem Wellendurchmesser d1, s. Tabelle. Der
    Nutdurchmesser ist abhaengig vom\
    Wellendurchmesser mit h10
    /h11/h12/h13 zu tolerieren, die Nutbreite mit H13. Um eine\
    nhinreichende Tragfaehigkeit der Wellennut zu
    gewaehrleisten, muss eine Bundbreite n\
    nmindestens
    vorhanden sein. Die Ta-belle unten ist ein Auszug aus DIN
    471. Die normgerechte\
    Bezeichnung lautet: Sicherungsring
    DIN 471 d1 x s, also z. B. Sicherungsring DIN 471 35 x
    1,5.\
    n(Quelle: Kuenne, B. (2016): Maschinenelemente kompakt
    . Band 1: Technisches Zeichnen.\
    n1. Auflage. 3. Auflage.
    Soest: Maschinenelemente-Verlag.")
87 label16.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
88 label16.configure(font=("Arial", resize_10))
89 elif selected_item == 'Zentrierbohrung':
90 label17 = ttk.Label(root, text="Diese Zentrierbohrungen
    erlauben dann die Spannung von Werkstuecken bei der
    Bearbeitung\
    auf Drehmaschinen. Zentrierbohrer koennen auch
    zum Anbohren verwendet werden, damit\
    nein nachfolgendes
    Bohrwerkzeug in der Bearbeitung nicht verlaeuft. Je nach
    Verwendungs-\
    nzweck gibt es verschiedene Formen von
    Zentrierbohrern.\
    n(Quelle: https://www.sppw.de/de/
    zerspanunganwendungen/zentrierbohrerzentrieren)")
91 label17.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
92 label17.configure(font=("Arial", resize_10))
93 elif selected_item == 'Ritzelwelle':
94 label18 = ttk.Label(root, text="Bei einer Ritzelwelle sind die
    Zaehne in die Welle integriert, wohingegen Zanhraeder bei
    der\
    nMonatge auf eine Welle aufgesetzt und
    drehmomentschluessig verbunden werden.")
95 label18.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
96 label18.configure(font=("Arial", resize_10))
97 elif selected_item == 'Zahn bzw. Zahnrad':
```

```
98 label19 = ttk.Label(root , text="Zahnraeder dienen der
    Uebertragung von Drehmoment und Drehzahl sowie der
    Verlagerung\nder Drehachsen. Die Darstellung von
    Zahnraedern ist in DIN ISO 2203 genormt.\n(Quelle: Kuenne,
    B. (2016): Maschinenelemente kompakt. Band 1: Technisches
    Zeichnen.\n1. Auflage. 3. Auflage. Soest: Maschinenelemente
    -Verlag.")
99 label19.place(x=1250*resfacwidth , y=700*resfacheight , width
    =700*resfacwidth , height=250*resfacheight)
100 label19.configure(font=("Arial" , resize_10))
101 elif selected_item == 'Passfeder':
102 label20 = ttk.Label(root , text="Passfederverbindungen
    uebertragen ein Drehmoment zwischen der Welle und dem\
    naufgesetzten Bauteil. Passfedern "federn" nicht , sondern
    stellen sinn-gemaess eine\nNut-und Feder-Verbindung wie bei
    Brettern dar. Der Passfederquerschnitt und ihr\
    nLaengenbereich sind durchmesser-abhaengig. Die normgerechte
    Bezeichnung lautet:\nPassfeder (Form) b x h x l DIN 6885,
    also z. B. Passfeder A 10 x 8 x 45 DIN 6885\n(Quelle:
    Kuenne, B. (2016): Maschinenelemente kompakt. Band 1:
    Technisches Zeichnen.\n1. Auflage. 3. Auflage. Soest:
    Maschinenelemente-Verlag.")
103 label20.place(x=1250*resfacwidth , y=700*resfacheight , width
    =700*resfacwidth , height=250*resfacheight)
104 label20.configure(font=("Arial" , resize_10))
105 elif selected_item == 'Gewinde':
106 label21 = ttk.Label(root , text="Das Gewinde ist eine
    profilierte Einkerbung, die fortlaufend wendelartig (also
    als\nSchraubenlinie) in einer zylinderfoermigen Innen- oder
    Aussenwand verlaeuft. Diese\nfortlaufende Vertiefung wird
    als Gewindegang auf einer Schraube bzw. in einer\nMutter
    bezeichnet. Das gaengigste Gewinde ist das metrische (Spitz-
    -)Gewinde nach\nDIN 13-1 (rechts oben), das durch den
    Buchstaben M vor dem Aussendurchmesser\ngekennzeichnet wird
    , z. B. M16. Es hat spitze Gewindegange mit einem
    Flankenwinkel\nvon 60 grad und wird fuer
    Befestigungsgewinde (Schrauben) eingesetzt. Soll bei
    Bewegungs-\ngewinden (Spindeln) eine haeufige Verstellung
    erfolgen , wird das stabilere Trapezgewinde\nnach DIN 103-2
```

```

(Bild rechts Mitte) eingesetzt. Dieses wird durch die
Buchstaben Tr,\nden Aussendurchmesser und die Steigung, d.
h. den Abstand zweier benachbarter\nGewindegaenge,
gekennzeichnet, beispielsweise Tr24x3.\n(Quellen: https://
de.wikipedia.org/wiki/Gewinde;\nKuenne, B. (2016):
Maschinenelemente kompakt. Band 1: Technisches Zeichnen.\n1
. Auflage. 3. Auflage. Soest: Maschinenelemente-Verlag.")
107 label21.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
108 label21.configure(font=("Arial", resize_10))
109 elif selected_item == 'Sicherungsblechnut':
110 label22 = ttk.Label(root, text="Sicherungsbleche besitzen am
    Innendurchmesser eine Nase, die in die eine Nut in\nder
    Welle eingefuehrt wird. Diese Sicherungsblechnut dient als
    Drehsicherung, \ndamit sich Wellenmutter und
    Sicherrungsblech nnicht von der Welle loesen.")
111 label22.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
112 label22.configure(font=("Arial", resize_10))
113 elif selected_item == 'Wellenmutter und Sicherungsblech':
114 label23 = ttk.Label(root, text="Wellenmuttern DIN 981 mit
    Feingewinde werden zur Festlegung von Lagern und sonstigen\n
    nBauteilen auf Wellen verwendet. Sie werden mit
    Sicherungsblechen DIN 5406 dadurch\ngesichert, dass die
    Nase des Sicherungsblechs in eine Nut in der Welle
    eingreift und einer\nder aeusseren Lappen in eine Nut der
    Wellenmutter umgebogen wird. Die normgerechte\nBezeichnung
    lautet beispielsweise Wellenmutter DIN 981 – KM 18.\n(
    Quelle: Kuenne, B. (2016): Maschinenelemente kompakt. Band
    1: Technisches Zeichnen.\n1. Auflage. 3. Auflage. Soest:
    Maschinenelemente-Verlag.")
115 label23.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
116 label23.configure(font=("Arial", resize_10))
117 elif selected_item == 'O-Ring':
118 label24 = ttk.Label(root, text=\O-Ringe werden entweder radial
    aussendichtend, also in einer Nut des Innenteils bei\n
    nglattem Aussenteil, oder radial innendichtend, d. h. in
    einer Nut des Aussenteils bei\nglattem Innenteil, verwendet

```

```

. Die axial dichtende Anordnung ist weniger gebraeuchlich.\
nDie normgerechte Bezeichnung lautet: O-Ring DIN 3771 – d1x
  d2 – N – NBR, also z. B.\nO-Ring DIN 3771 – 40 x 3,55 – N
– NBR; N bedeutet fuer allgemeine Anwendung, NBR\nist der
Werkstoff.\n(Quelle: Kuenne, B. (2016): Maschinenelemente
kompakt. Band 1: Technisches Zeichnen.\n1. Auflage. 3.
Auflage. Soest: Maschinenelemente–Verlag.\)
119 label24.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
120 label24.configure(font=("Arial", resize_10))
121 elif selected_item == 'Rillenkugellager':
122 label25 = ttk.Label(root, text="Rillenkugellager sind nach DIN
    625 genormt und sind eher fuer die Ueber–tragung\nvon
    Radialkraefte geeignet.\n(Quelle: Kuenne, B. (2016):
    Maschinenelemente kompakt. Band 1: Tech–nisches Zeichnen.\
    n1. Auflage. 3. Auflage. Soest: Maschinenelemente–Verlag.")
123 label25.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
124 label25.configure(font=("Arial", resize_10))
125 elif selected_item == 'Bohrung':
126 label26 = ttk.Label(root, text="Bohrungen sind zylindrische
    Volumensubtraktionen in einem Bauteil, die durch das Bohren
    \nmit einem Bohrer hergestellt werden.")
127 label26.place(x=1250*resfacwidth, y=700*resfacheight, width
    =700*resfacwidth, height=250*resfacheight)
128 label26.configure(font=("Arial", resize_10))
129 else:
130 pass
131 else:
132 pass
133
134 #Bildgroesse des detektierten Bildes wird an die Aufloesung
    und das Fenster angepasst
135 def resize_image():
136 basewidth = int(1100*resfacwidth)
137 baseheight= int(650*resfacheight)
138 fp = open("C:/Users/dillenhoefer/Documents/Yolov4/inference/
    output/detectedimage.png", "rb")
139 img1 = PIL.Image.open(fp)

```

```
140 wpercent = (baseheight / float(img1.size[1]))
141 wsize = int((float(img1.size[0]) * float(wpercent)))
142 if wsize >1100:
143 wpercent2 = (basewidth / float(img1.size[0]))
144 hsize = int((float(img1.size[1]) * float(wpercent)))
145 img1 = img1.resize((basewidth, hsize), PIL.Image.LANCZOS)
146 else:
147 img1 = img1.resize((wsize, baseheight), PIL.Image.LANCZOS)
148 img1.save('C:/Users/dillenhoefer/Documents/Yolov4/inference/
    output/detectedimage_resized.png')
149
150 #Erstelle Widgets zum Einlade der zu detektierenden Datei
151 def CreateWidgets():
152 link_label = Label(root, text="Select the file")
153 link_label.place(x=100*resfacwidth, y=150*resfacheight)
154 root.sourceText = Entry(root, width=resize_50, textvariable=
    sourcelocation)
155 root.sourceText.place(x=200*resfacwidth, y=150*resfacheight)
156 source_browseButton = Button(root, text="browse", command=
    SourceBrowse, width=resize_15)
157 source_browseButton.place(x=500*resfacwidth, y=150*
    resfacheight)
158 copyButton = Button(root, text="copy file", command=CopyFile,
    width=resize_15)
159 copyButton.place(x=275*resfacwidth, y=200*resfacheight)
160
161
162 def SourceBrowse():
163 root.files_list = list(filedialog.askopenfilenames())
164 root.sourceText.insert('1', root.files_list)
165
166 #Kopiere das Bild an die gewuenschte Stelle
167 def CopyFile():
168 files_list = root.files_list
169 destination_location = "C:/Users/dillenhoefer/Documents/Yolov4
    /data/Dissgui/detectedimage.png"
170 destination_location_txt = "C:/Users/dillenhoefer/Documents/
    Yolov4/inference/output/detected.txt"
171 for f in files_list:
```

```
172 shutil.copy(f, destination_location)
173 messagebox.showinfo("Successful")
174
175 #Fuehre die Batch Datei aus Anhang A aus
176 def batexe():
177     subprocess.call([r'C:/Users/dillenhoefer/PycharmProjects/Diss/
        python.bat'])
178
179 #Oeffne Oberflaeche fuer ChatGPT
180 def openchatgpt():
181     webview.create_window('Weitere Hilfe durch Chat GPT', 'https
        ://chat.openai.com/auth/login?next=%2F')
182     webview.start()
183
184 #Lege eine Liste an, die die gefundenen Klassen enthaelt
185 def legearrayan():
186     a=open("C:/Users/dillenhoefer/Documents/Yolov4/inference/
        output/detectedimage.txt", 'r')
187     b=open("C:/Users/dillenhoefer/Documents/Yolov4/inference/
        output/detectedimage.txt", 'r')
188     RWDR=0
189     WM=0
190     FS=0
191     FA=0
192     SR=0
193     ZB=0
194     RW=0
195     ZZ=0
196     PF=0
197     GW=0
198     SBN=0
199     WSB=0
200     OR=0
201     SKL=0
202     RKL=0
203     BO=0
204     DB=0
205     for i in range(1, 99):
206         erkennung1 = a.readline(2)
```

```
207 leer1 = a.readline()
208 if erkennung1.isdigit():
209     if erkennung1 == "10":
210         # print("Sicherungsblechnut")
211         SBN += 1
212     elif erkennung1 == "11":
213         # print("Wellenmutter und Sicherungsblech")
214         WSB += 1
215     elif erkennung1 == "12":
216         # print("O-Ring")
217         OR += 1
218     elif erkennung1 == "13":
219         # print("Schraegkugellager")
220         SKL += 1
221     elif erkennung1 == "14":
222         # print("Rillenkugellager")
223         RKL += 1
224     elif erkennung1 == "15":
225         # print("Bohrung")
226         BO += 1
227     elif erkennung1 == "16":
228         # print("Distanzbuchse")
229         DB += 1
230     elif erkennung1 == "17":
231         # print("Radialwellendichtring")
232         RWDR += 1
233     elif erkennung1 == " ":
234         print("Leerzeichen")
235     else:
236         # print("keine Erkennung gefunden")
237         pass
238     # folge.append("keine Erkennung gefunden")
239     else:
240         if erkennung1 == "0 ":
241             # print("Radialwellendichtring")
242             RWDR += 1
243         elif (erkennung1 == "1 ") and (not erkennung1.isdigit()):
244             # print("Wellenmutter")
245             WM += 1
```

```
246 elif erkennung1 == "2 ":
247 # print ("Freistich ")
248 FS+=1
249 elif erkennung1 == "3 ":
250 # print ("Fase ")
251 FA+=1
252 elif erkennung1 == "4 ":
253 # print ("Sicherungsring ")
254 SR+=1
255 elif erkennung1 == "5 ":
256 # print ("Zentrierbohrung ")
257 ZB+=1
258 elif erkennung1 == "6 ":
259 # print ("Ritzelwelle ")
260 RW+=1
261 elif erkennung1 == "7 ":
262 # print ("Zahn bzw. Zahnrad ")
263 ZZ+=1
264 elif erkennung1 == "8 ":
265 # print ("Passfeder ")
266 PF+=1
267 elif erkennung1 == "9 ":
268 # print ("Gewinde ")
269 GW+=1
270 folgeleer=len(folge)
271 if folgeleer==0:
272 if RWDR >0:
273 folge.append("Radialwellendichtring ")
274 else:
275 pass
276 if WM >0:
277 folge.append("Wellenmutter ")
278 else:
279 pass
280 if FS >0:
281 folge.append("Freistich ")
282 else:
283 pass
284 if FA >0:
```

```
285 folge.append(" Fase ")
286 else :
287 pass
288 if SR >0:
289 folge.append(" Sicherungsring ")
290 else :
291 pass
292 if ZB >0:
293 folge.append(" Zentrierbohrung ")
294 else :
295 pass
296 if RW >0:
297 folge.append(" Ritzelwelle ")
298 else :
299 pass
300 if ZZ >0:
301 folge.append(" Zahn bzw. Zahnrad ")
302 else :
303 pass
304 if PF >0:
305 folge.append(" Passfeder ")
306 else :
307 pass
308 if GW >0:
309 folge.append(" Gewinde ")
310 else :
311 pass
312 if SBN >0:
313 folge.append(" Sicherungsblechnut ")
314 else :
315 pass
316 if WSB >0:
317 folge.append(" Wellenmutter und Sicherungsblech ")
318 else :
319 pass
320 if OR >0:
321 folge.append(" O-Ring ")
322 else :
323 pass
```

```
324 if SKL >0:
325     folge.append(" Schraegkugellager ")
326 else:
327     pass
328 if RKL >0:
329     folge.append(" Rillenkugellager ")
330 else:
331     pass
332 if BO >0:
333     folge.append(" Bohrung ")
334 else:
335     pass
336 if DB >0:
337     folge.append(" Distanzbuchse ")
338 else:
339     pass
340 if erkennung1 == " ":
341     print(" Leerzeichen ")
342 else:
343     pass
344 else:
345     pass
346
347 #ab hier: Erstelle die Benutzeroberflaeche
348 root = tk.Tk()
349 root.title("KI Tool fuer Technische Zeichnungen – Fachgebiet
           Maschinenelemente – von Fabian Dillenhoefer")
350 root.attributes("-fullscreen", True)
351 screen_width = root.winfo_screenwidth()
352 screen_height = root.winfo_screenheight()
353 screen_resolution = str(screen_width)+'x'+str(screen_height)
354 root.geometry(screen_resolution)
355 print(screen_resolution)
356 resfacheight = float(screen_height/1080)
357 resfacwidth= float(screen_width/1920)
358 print(resfacwidth)
359 resize_5=int(8*resfacwidth)
360 resize_10=int(10*resfacwidth)
361 resize_15=int(15*resfacwidth)
```

```
362 resize_20=int(50*resfacwidth)
363 resize_50=int(50*resfacwidth)
364 resize_150=int(150*resfacwidth)
365
366 style= ttk.Style()
367 fp = open("ME_Logo_Schatten_mitSchrift.png", "rb")
368 image2 = PIL.Image.open(fp)
369 photo = ImageTk.PhotoImage(image2)
370 label1 = ttk.Label(root, text="Willkommen zum Hilfstool fuer
    Technischen Zeichnungen")
371 label1.place(x=500*resfacwidth, y=30*resfacheight)
372 label2 = ttk.Label(root, image=photo, compound="top")
373 label2.place(x=100*resfacwidth, y=980*resfacheight)
374 label1.configure(font=("Arial",20))
375 label3 = ttk.Label(root, text="Schritt 1: Bildimport")
376 label3.place(x=250*resfacwidth, y=100*resfacheight)
377 label3.configure(font=("Arial",resize_15))
378 label4 = ttk.Label(root, text="Schritt 2: Detection")
379 label4.place(x=800*resfacwidth, y=100*resfacheight)
380 label4.configure(font=("Arial",resize_15))
381 label41 = ttk.Label(root, text="Schritt 3: Detections")
382 label41.place(x=1300*resfacwidth, y=100*resfacheight)
383 label41.configure(font=("Arial",resize_15))
384 button1 = ttk.Button(root, text="Exit", command=root.quit,
    width=resize_15)
385 button1.place(x=1750*resfacwidth, y=980*resfacheight)
386 button3 = ttk.Button(root, text="Start Detection",command=
    batexe)
387 button3.place(x=820*resfacwidth, y=150*resfacheight, height
    =50*resfacheight, width=150*resfacwidth)
388 label44 = ttk.Label(root, text="
    ")
389 label44.place(x=1*resfacwidth, y=230*resfacheight)
390 label42 = ttk.Label(root, text="Detected Image:")
391 label42.place(x=100*resfacwidth, y=270*resfacheight)
392 label42.configure(font=("Arial",resize_15))
393 label43 = ttk.Label(root, text="Gefundene Bauteile:")
394 label43.place(x=1250*resfacwidth, y=270*resfacheight)
```

```
395 label43.configure(font=("Arial",resize_15))
396 list_box = Listbox(root,height=resize_50,width=resize_10)
397 list_box.bind('<<ListboxSelect>>',insert_into_entry)
398 entry1 = Entry(root)
399 for g in folge:
400 list_box.insert(END,g)
401 chatgptButton = ttk.Button(root, text="Weiter recherchieren
        mit ChatGPT", command=openchatgpt, width=resize_20)
402 chatgptButton.place(x=1250*resfacwidth, y=980*resfacheight,
        width=300*resfacwidth, height=50*resfacheight)
403 sourcelocation = StringVar()
404 destinationLocation = StringVar()
405 Picture(root)
406 CreateWidgets()
407 root.mainloop()
```

# C Liste der Hochschulen aus NRW mit TZ-Bezug

Tabelle C.1: Liste der Hochschulen aus NRW mit TZ-Bezug

Hochschule	Stadt	Art	Modul TZ vorhanden	Modulhandbuch verfügbar
FH Aachen	Aachen	FH	Ja	Nein
RWTH Aachen	Aachen	Uni	Ja	Ja
FH Bielefeld	Bielefeld	FH	Ja	Ja
FH des Mittelstandes	Bielefeld	FH	Ja	Nein
Westfälische HS	Gelsenkirchen	FH	Ja	Ja
HS Bochum	Bochum	FH	Ja	Ja
Ruhr-Uni Bochum	Bochum	Uni	Ja	Ja
TH Georg Agricola	Bochum	FH	Ja	Ja
Europäische FH	Brühl	FH	Ja	Nein
FH Dortmund	Dortmund	FH	Ja	Ja
TU Dortmund	Dortmund	Uni	Ja	Ja
Uni Duisburg-Essen	Duisburg	Uni	Ja	Ja
HS Düsseldorf	Düsseldorf	FH	Ja	Ja
HS für Ökon. und Man.	Essen	FH	Ja	Nein
HS Hamm-Lippstadt	Hamm	FH	Ja	Ja
SRH HS	Hamm	FH	Ja	Nein
FH Südwestfalen	Iserlohn/Soest	FH	Ja	Ja
HS Rhein-Waal	Kleve	FH	Ja	Ja
HS Fresenius	Köln	FH	Ja	Nein
TH Köln	Köln	FH	Ja	Ja
Rheinische FH Köln	Köln	FH	Ja	Nein
HS Niederrhein	Krefeld	FH	Ja	Ja
TH Ostwestfalen	Lemgo	FH	Ja	Ja
HS Ruhr-West	Mühlheim (Ruhr)	FH	Ja	Ja
FH Münster	Münster	FH	Ja	Nein
Uni Paderborn	Paderborn	Uni	Ja	Ja
HS Bonn-Rhein-Sieg	Sankt Augustin	FH	Ja	Nein
Uni Siegen	Siegen	Uni	Ja	Ja
BUW Wuppertal	Wuppertal	Uni	Ja	Ja

## D Umfrageergebnisse der initialen Befragung zu TZ Digital.nrw

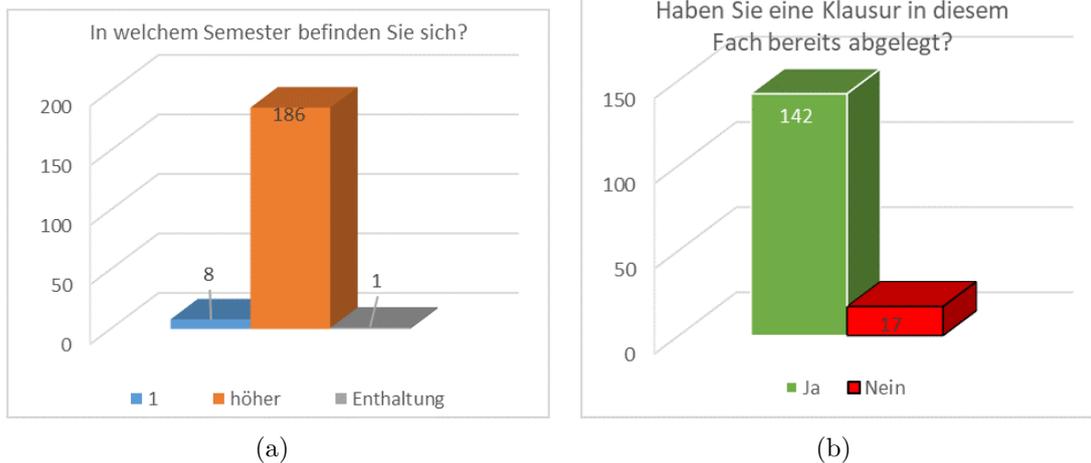


Abbildung D.1: Anzahl absolvierter Semester und Erfahrungen zur Klausur

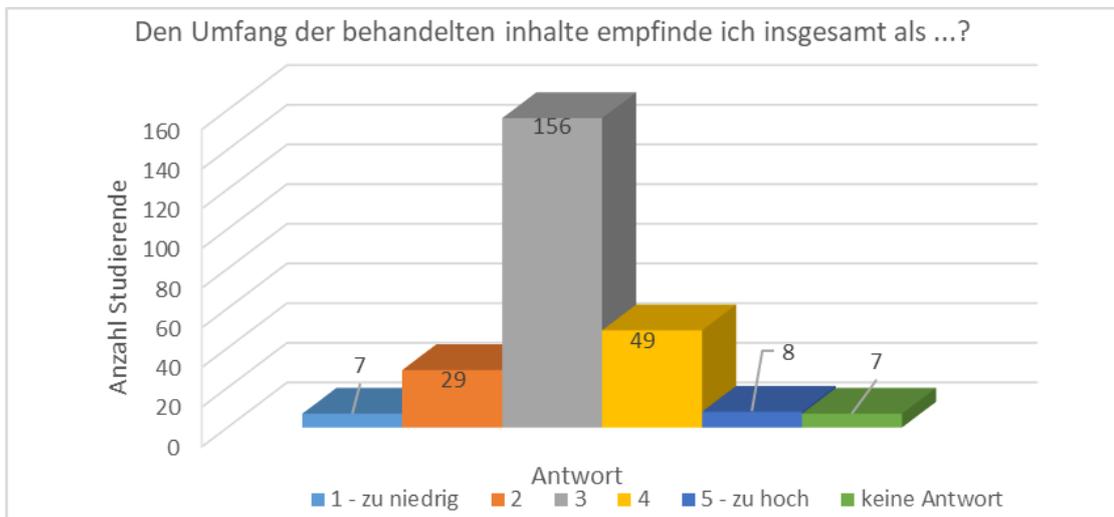


Abbildung D.2: Umfang der Lerninhalte

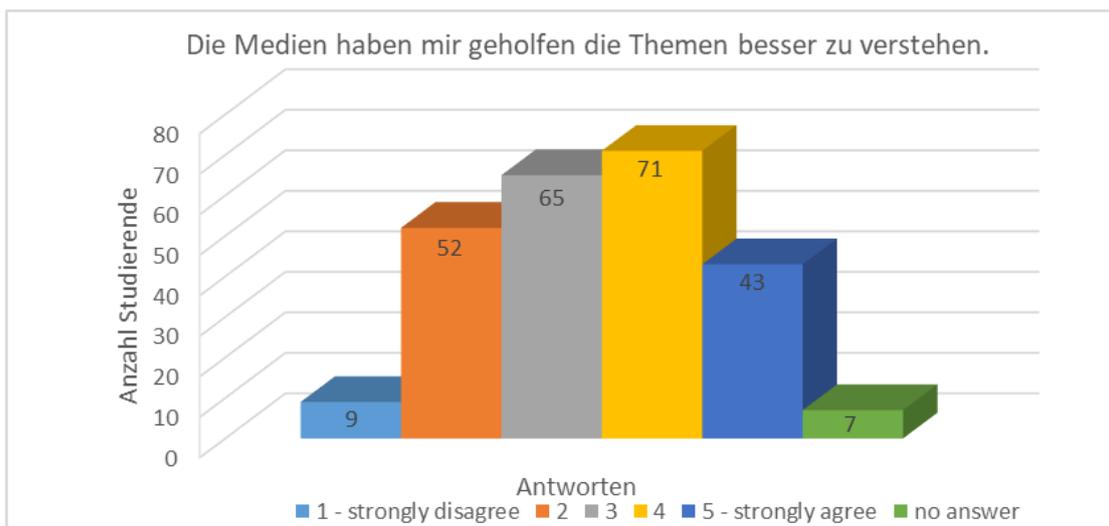


Abbildung D.3: Mediendidaktische Aufbereitung

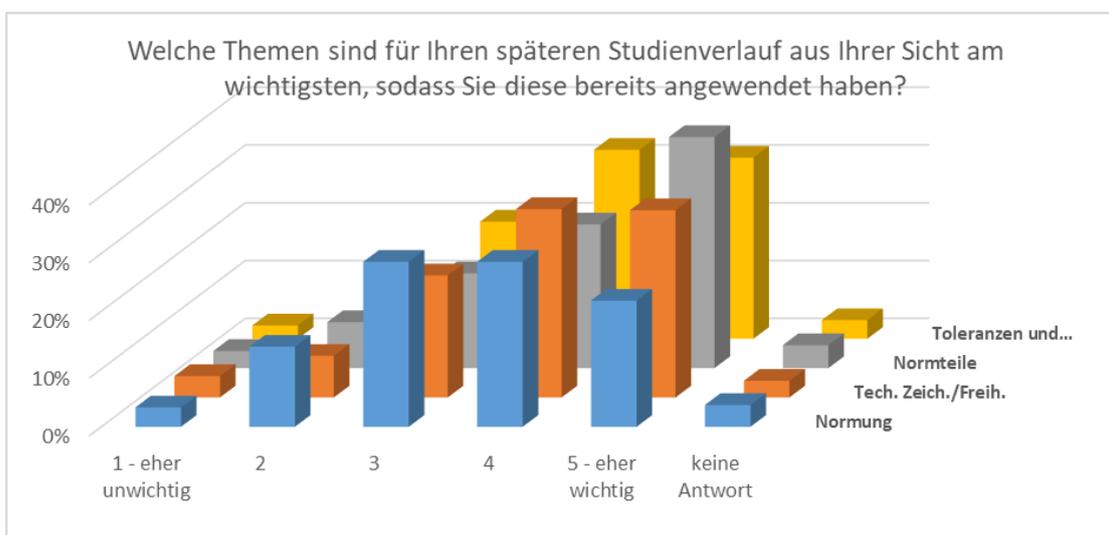


Abbildung D.4: Wichtigkeit der Themen aus Sicht der Studierenden

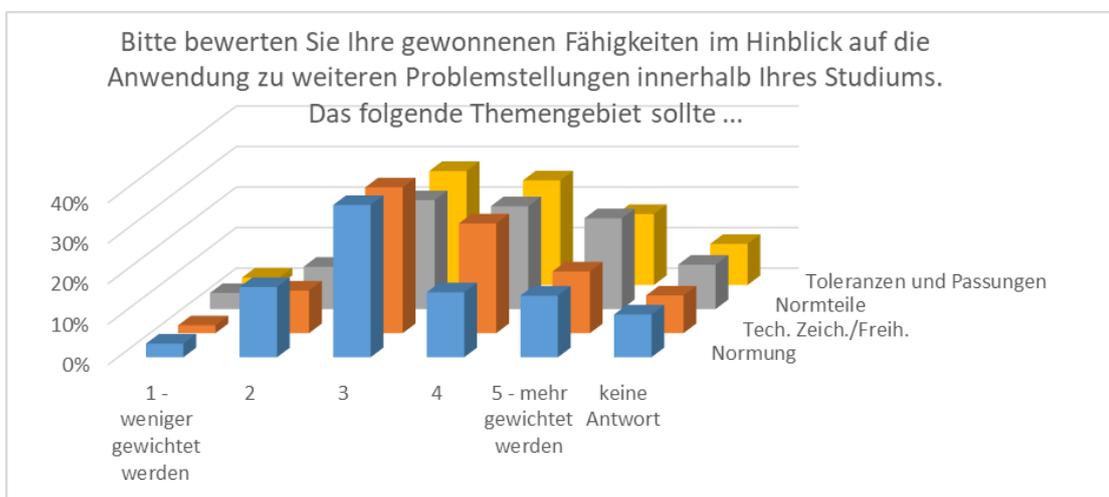


Abbildung D.5: Gewichtung der Themen

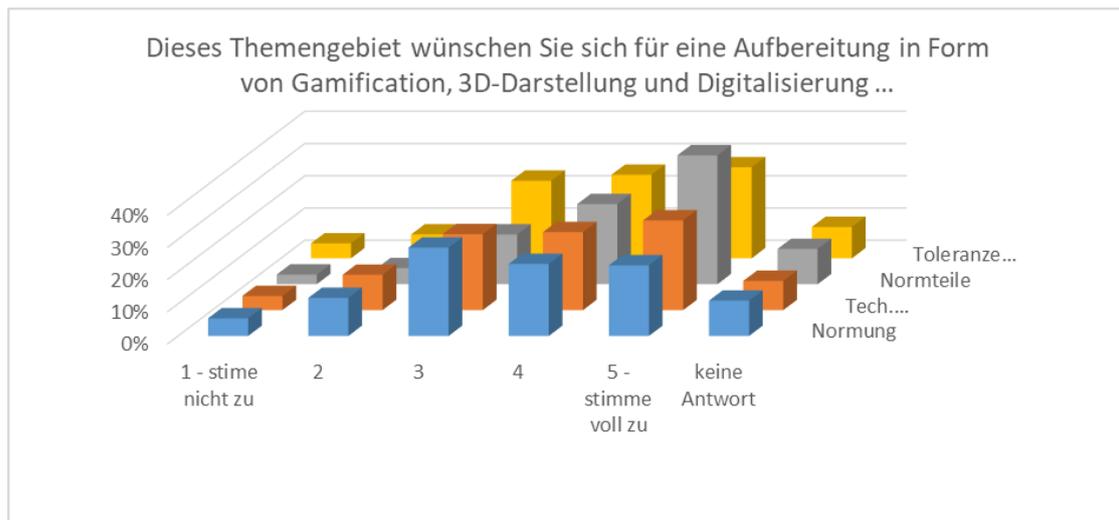


Abbildung D.6: Digitale Aufbereitung

### Anmerkungen der Studierenden in Open-Text Antwortboxen:

- Volumenkörper der entsprechenden Zeichnung zuordnen.
- App und Lernvideos
- Weniger „zu Fuß“ rechnen, eher Anwendung im CAD lernen Mit in der Realität verbauten Teilen vergleichen, mehr ERFAHRUNGSWERTE sammeln, es wird ja nicht jeder Passstift einzeln ausgerechnet ;)
- Man Könnte in dem CAD Modul eine Projektaufgabe in Gruppen bearbeiten, wo eine leichte Baugruppe mit jedem Detail erstellt werden muss.
- Simulationen von Verbindungen mit einstellbaren Parametern
- Das größte Problem am Technischen Zeichnen war für mich der Tropfenartige Lernprozess. Meiner Meinung nach wäre es hilfreich zu Beginn eine vollständige Zeichnung vorgezeichnet zu bekommen. Dieses wäre insofern hilfreich da man keine vollständige Technische Zeichnung zeichnen kann ohne alle Teilaspekte kennengelernt zu haben. Der Gamification Aspekt könnte mit Teilaufgaben gelöst werden. Also die gesamte Erklärung zu Beginn und dann Aufgaben zu einzelnen Teilen.
- Anhand einer nachgespielten Konstruktion eines Produkts mit kleinem Umfang (das verschiedene Gestaltungsmerkmale besitzt) sollte unter der Verwendung einer frei gewählten CAD-Software (wie dem kostenlos verfügbaren Autodesk-Fusion 360) eine Baugruppe erstellt werden. Nachgelagert sollten Zeichnungsableitungen mit Schnittansichten von Einzelteilen und eine Assembly-Zeichnung folgen. Basis für die Aufgabe könnte ein ähnliches Produkt sein für das alle Schritte mit Beschreibung der Vorgehensweise vorliegen. In dem Rahmen wird der Student /

die Studentin angeregt kreativ zu arbeiten mit dem Ziel der Erarbeitung eines kleinen Erfolgsmoments. Die Lehre (Vorlesung oder Übung) erfolgt an dem Referenzprodukt. Fazit: Studenten sollten frühzeitiger mit Software vertraut werden und die ersparte Zeit für Handzeichnungen in die Auseinandersetzung mit einem Programm stecken.

- Anschaffung/Nutzung von 3D-Brillen oder ähnlichen Komponenten zur besseren Veranschaulichung von Praxisbeispielen vor Ort (Universität); mehr Nutzung von digitalen Lösungen mit themenbasierten Aufbau und Transferwissen aus verschiedenen (Bildungs-, Studien-, Wirtschafts-) Bereichen
- Die Themen auf aktuellen Kontext anwenden. Die wenigsten Dinge werden noch von hand gezeichnet. Wichtiger wäre eine Verbindung zum Beispiel zu CAD. Auch dort müssen Teile bemaßt werden. Wo bringt man am besten Maße an etc. Gamification könnte man evtl. in Form von verschiedenen Level nutzen. Je besser die erstellen Zeichnung sind, umso mehr Punkte erhält man. Dadurch steigt man Stufen auf, erhält kompliziertere Zeichnungen und irgendwann Baugruppen, bis dass eine gewisse Punktzahl den Abschluss der Übung/ des Lehrgangs/ etc. markiert. Im Rahmen der Digitalisierung wäre es interessant sich mit AR zu beschäftigen um zu sehen wie dort Zeichnungen oder 3D Modelle visualisiert werden müssen und welche neuen Herausforderungen es dadurch gibt. Zum Beispiel ob man Maße und verschiedene Oberflächen anders darstellen kann als bisher aus klassischen Zeichnungen bekannt.
- Mit 3D Modellen lässt sich der Stoff leichter verstehen, es ist dann einfach anschaulicher.
- Finde ich eine gute Idee
- Diversität Wissen; mehr CAD; 2 ECTS zu wenig, obwohl Fach absolutes Grundlagenfach; Mit Vorwissen geschenkt
- Videos und Aufzeichnungen
- Videos
- Mehr CAD; ohne Vorwissen teilweise überfordert
- Räumliches Vorstellungsvermögen anhand von 2D-3D Beispielen
- Neue Medien einsetzen; Videos; zuerst auf das Wichtigste beschränken; Vertiefungen optional
- Einfach mit Vorwissen; ohne Vorwissen zu viel
- Online Übungen/Tutorien; bewertete Tests; hätte mehr Umfang vertragen können, jedoch mehr auf CAD Schwerpunkt legen

- Aus meiner Sicht wäre es durchaus zukunftsorientierter das Konstruktionsprojekt aus ME2 in einem 3D-CAD-Programm durchzuführen. In der späteren Arbeitswelt wird niemand mehr auf Papier zeichnen müssen.
- Sehr simpel bietet sich Google-SketchUP 3D an. Habe mir vieles darüber verbildlicht. Ist intuitiv und es reicht eine Browserinstalation. Hilft gerade bei Problemen mit dem räumlichen Denken
- Teile in 3D nachkonsturieren, visualisierung CAD 3D ist sehr wichtig für einen Ingenieur
- Die 3D Körperansichten waren immer sehr gut
- zu den gezeigten Maschinenelementen QR-Codes die zu 3D Animationen des Teils führen

## E Ergebnisse aus der Abschluss- evaluation

Hinweis: Auf der Ordinate sind jeweils die Anzahl der Studierenden angetragen

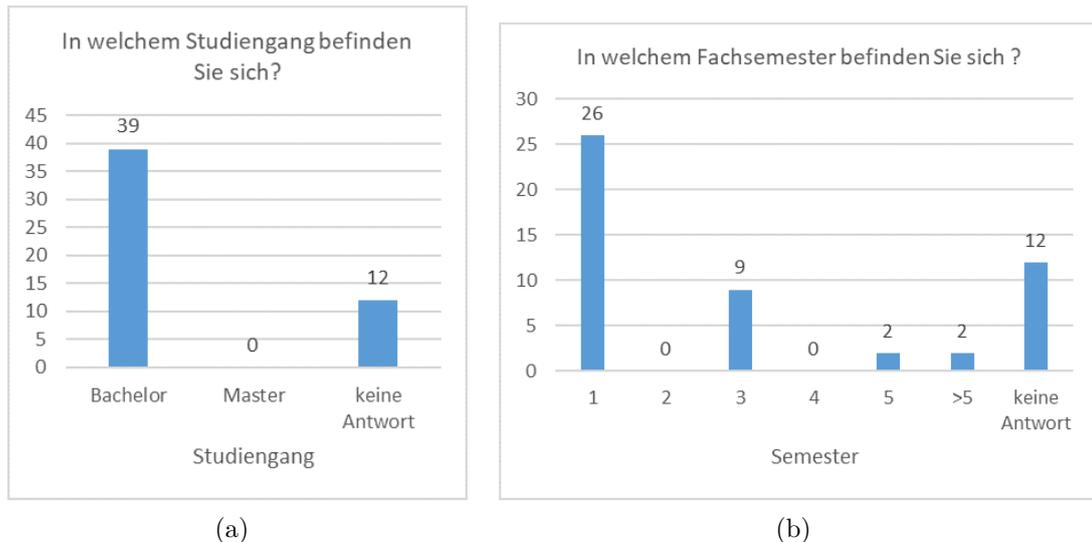


Abbildung E.1: Zuordnung zum Studiengang und Semesteranzahl

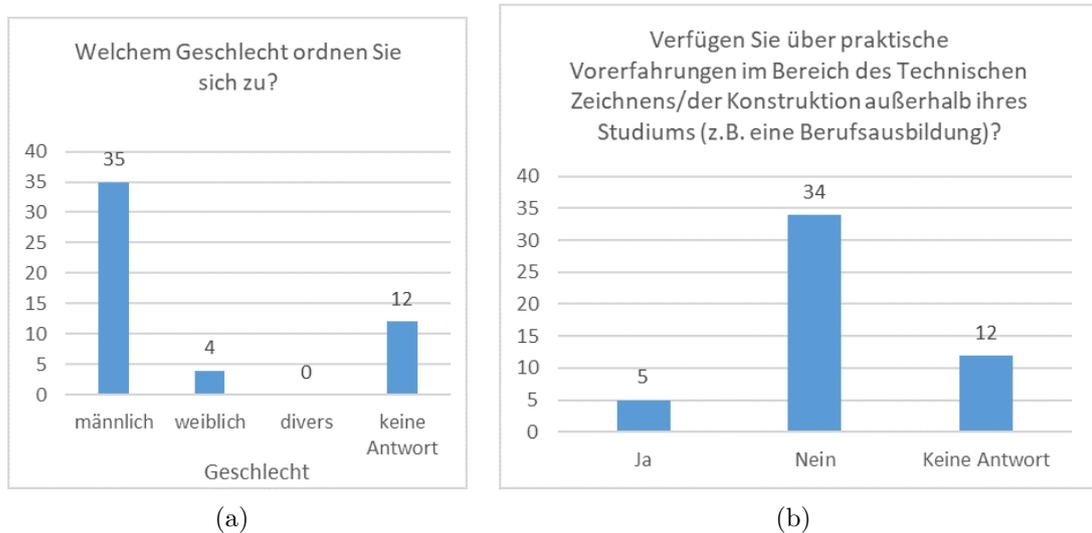


Abbildung E.2: Geschlechterzuordnung und Vorerfahrungen vor dem Studium

OER

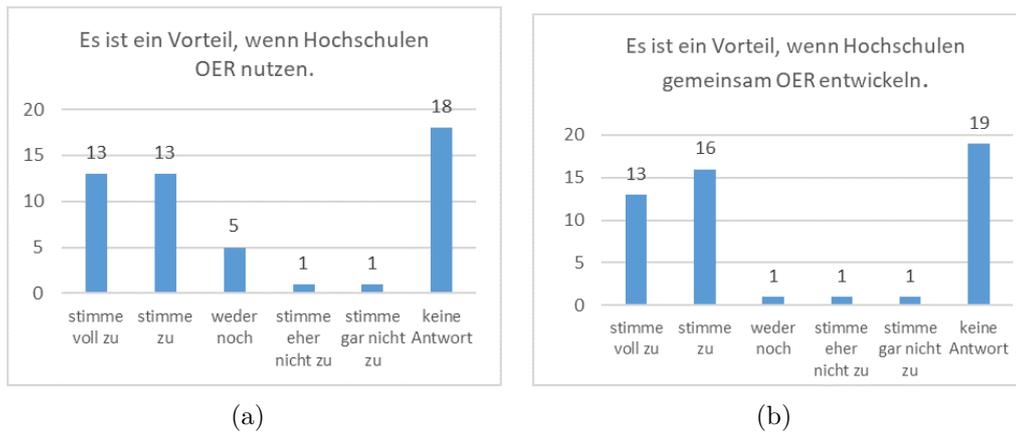


Abbildung E.3: Meinung und Entwicklung zu OER

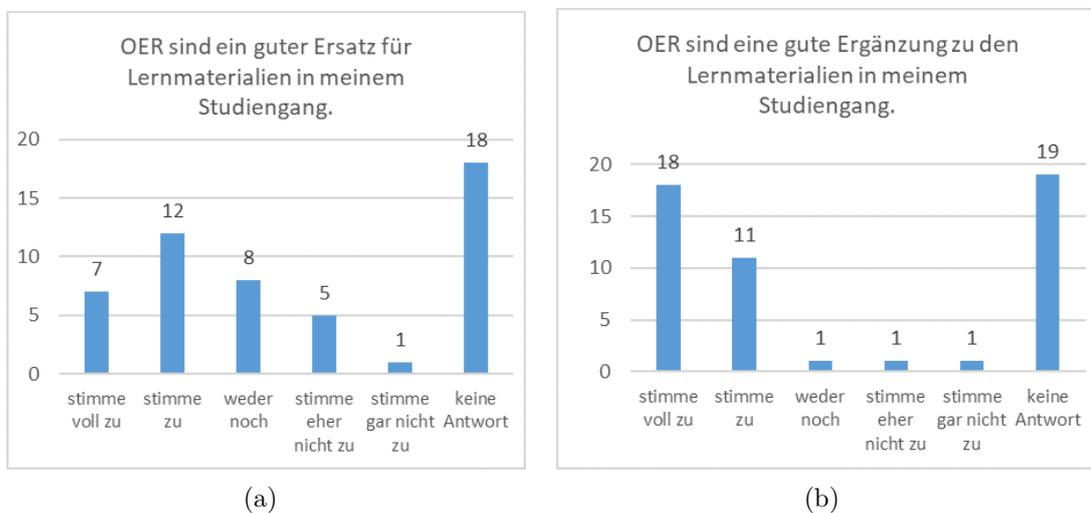


Abbildung E.4: Einsatz OER und Ergänzung zu vorhandenen Lernmaterialien

Themen allgemein

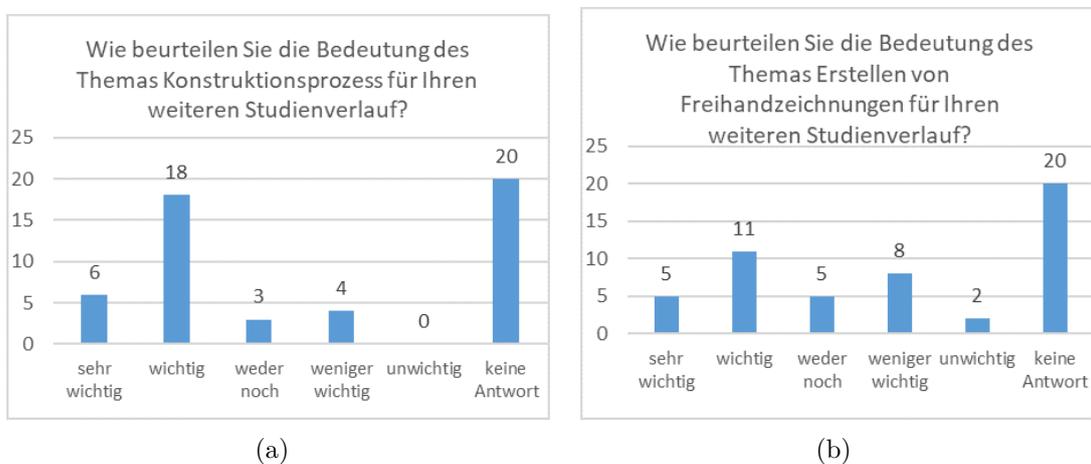


Abbildung E.5: Bedeutung der Themen Konstruktionsprozess und Erstellen von Freihandzeichnungen im Studienverlauf

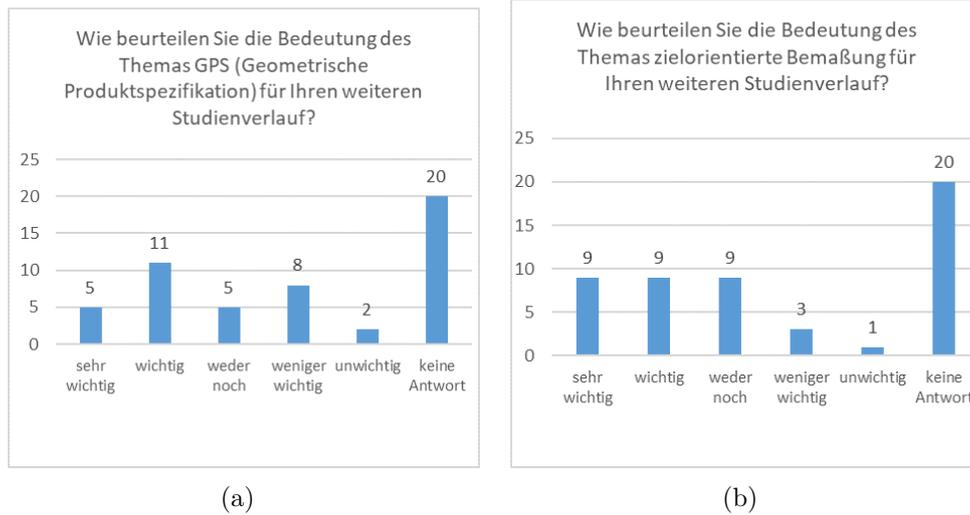


Abbildung E.6: Bedeutung der Themen GPS und zielorientierte Bemaßung im Studienverlauf

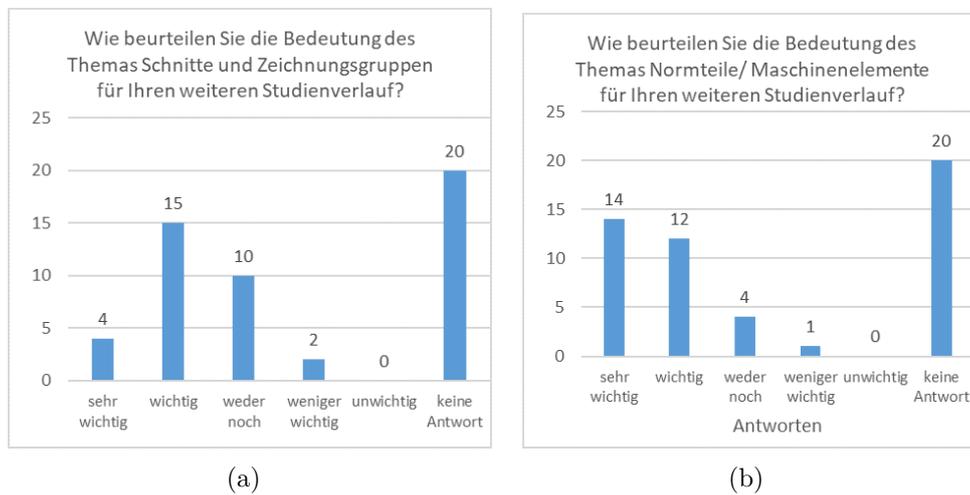


Abbildung E.7: Bedeutung der Themen Schnitte und Zeichnungsgruppen sowie Normteile und Maschinenelemente im Studienverlauf

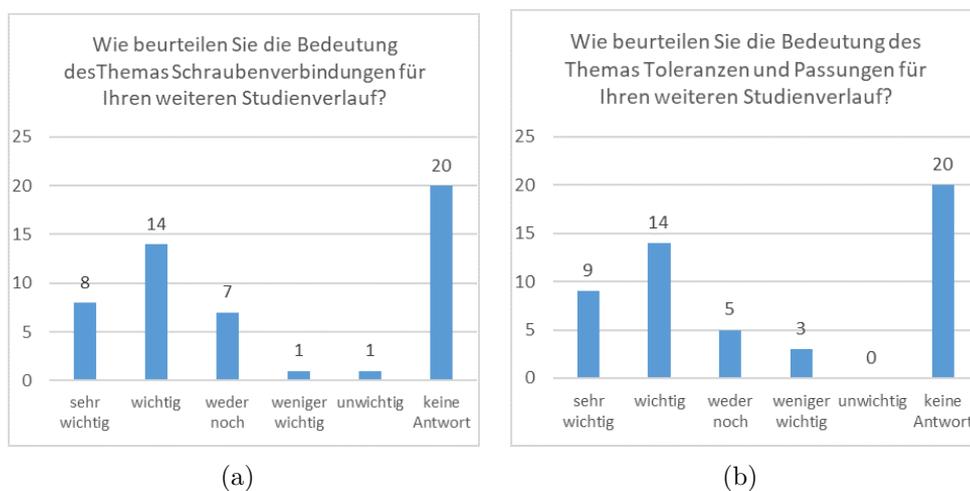


Abbildung E.8: Bedeutung der Themen Schraubenverbindungen sowie Toleranzen und Passungen im Studienverlauf

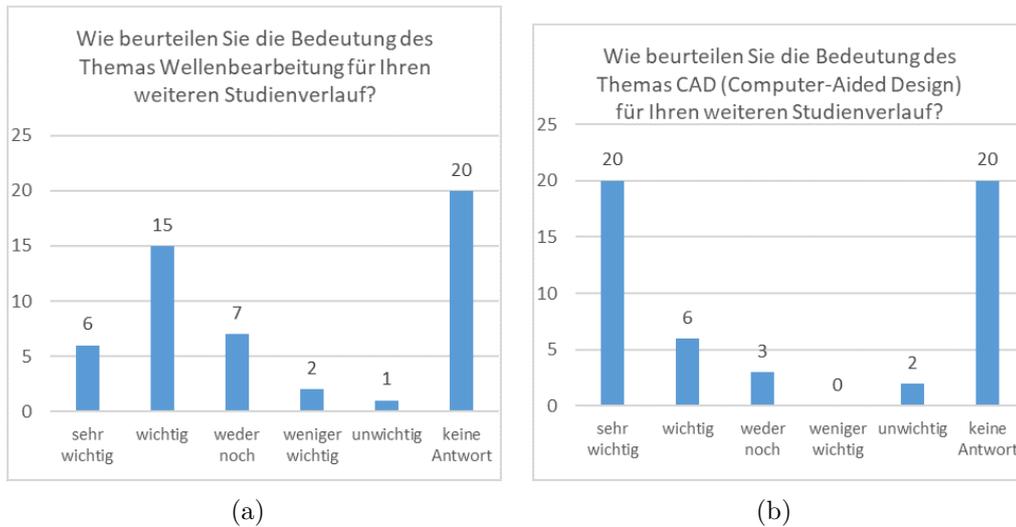


Abbildung E.9: Bedeutung der Themen Wellenbearbeitung und CAD im Studienverlauf

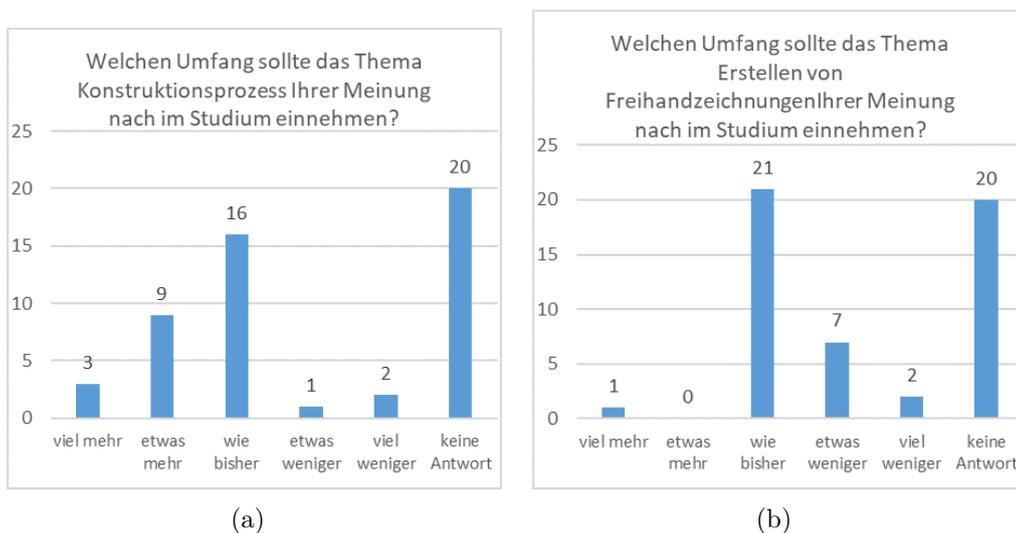


Abbildung E.10: Bedeutung des Themas Konstruktionsprozess und Umfang des Themas Freihandzeichnungen

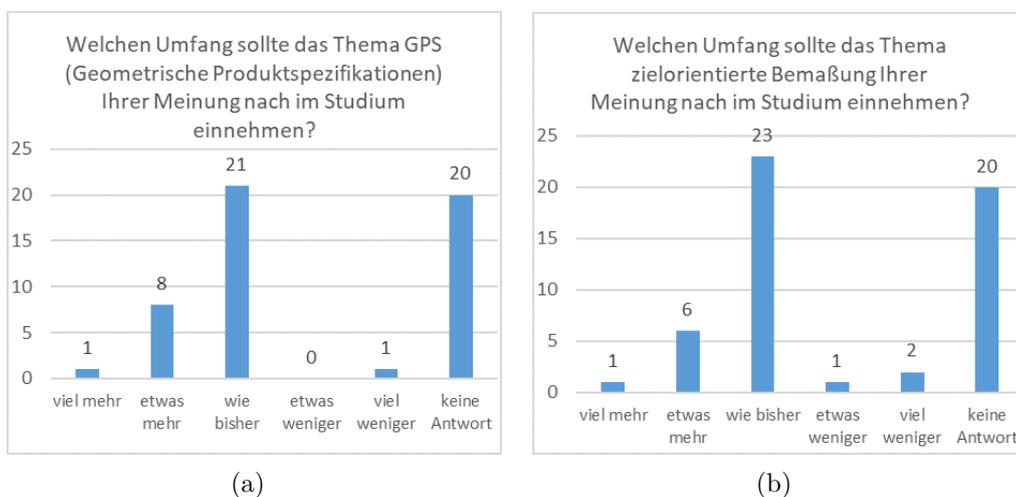


Abbildung E.11: Bewertung des Umfangs zu den Themen GPS und zielorientierte Bemaßung

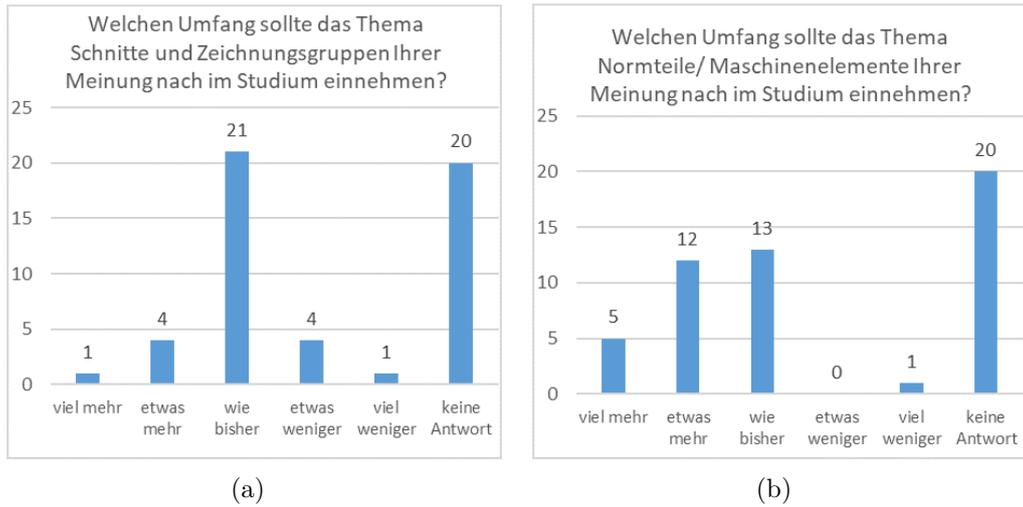


Abbildung E.12: Bewertung des Umfangs zu den Themen Schnitte und Zeichnungsgruppen sowie Normteile und Maschinenelemente

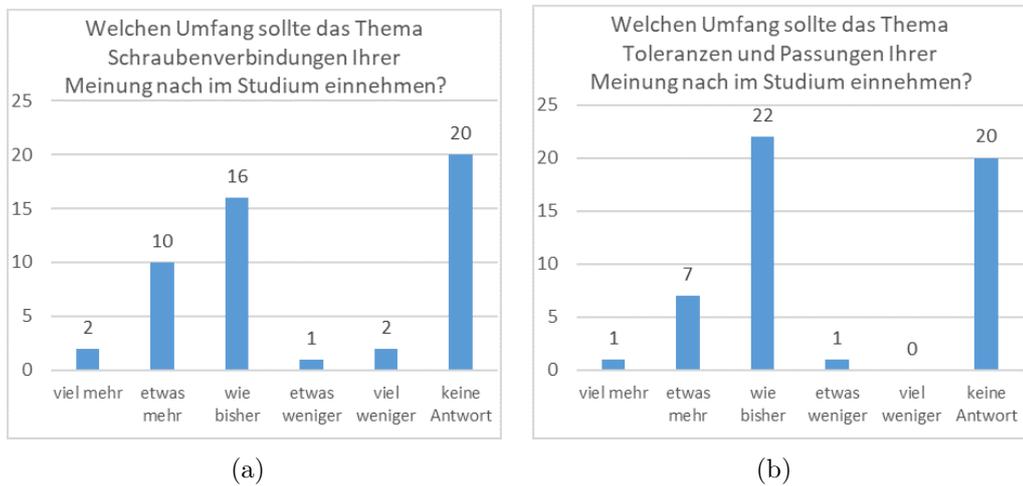


Abbildung E.13: Bewertung des Umfangs zu den Themen Schraubenverbindungen sowie Toleranzen und Passungen

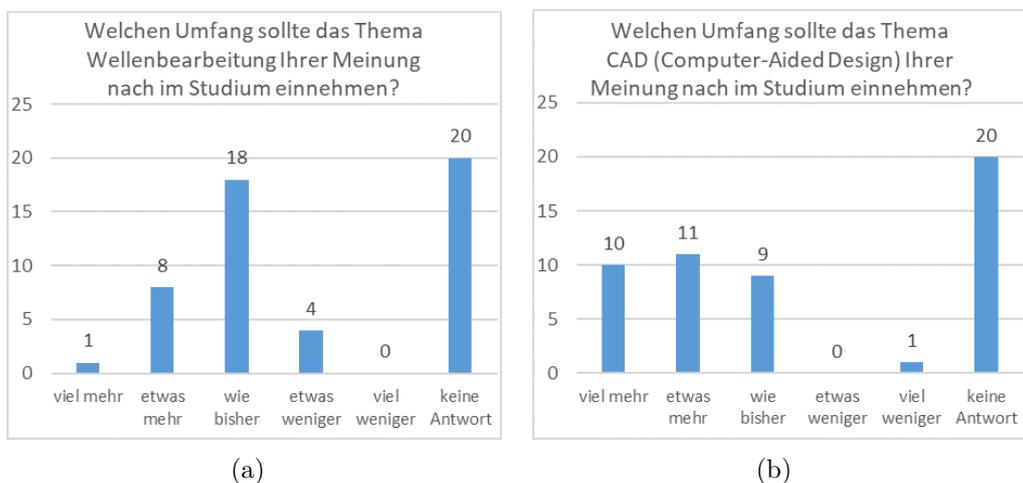


Abbildung E.14: Bewertung des Umfangs zu den Themen Wellenbearbeitung und CAD

**Persönliche Fähigkeiten**

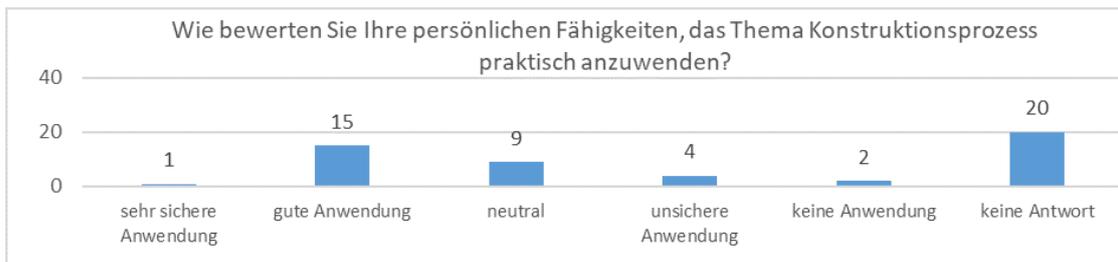


Abbildung E.15: Einschätzung der persönlichen Fähigkeiten zum Thema Konstruktionsprozess

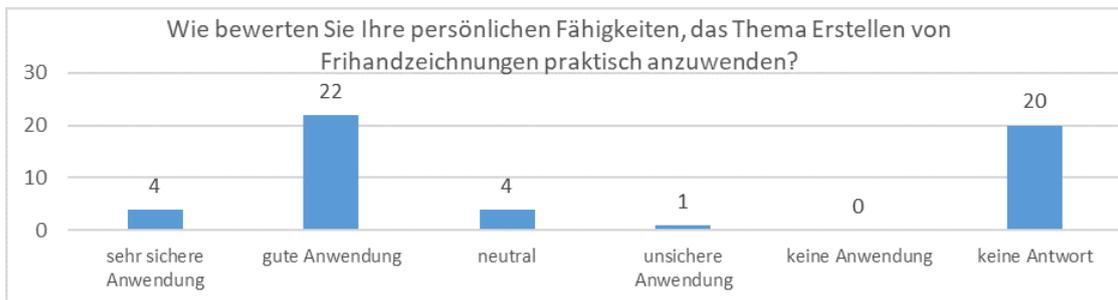


Abbildung E.16: Einschätzung der persönlichen Fähigkeiten zum Thema Erstellen von Freihandzeichnungen

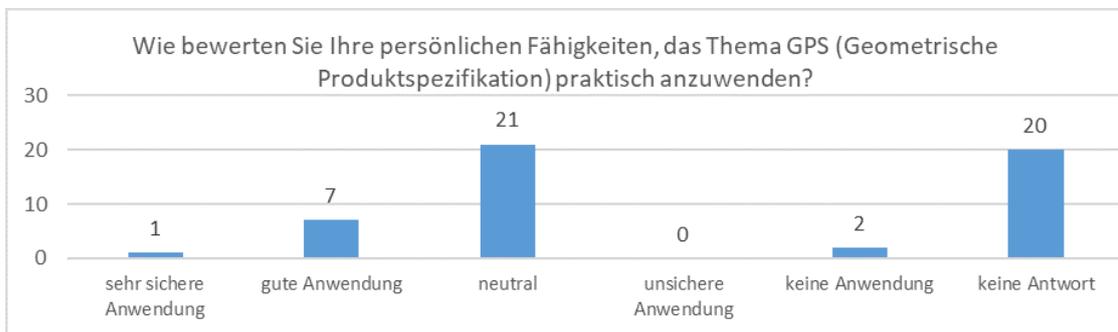


Abbildung E.17: Einschätzung der persönlichen Fähigkeiten zum Thema GPS

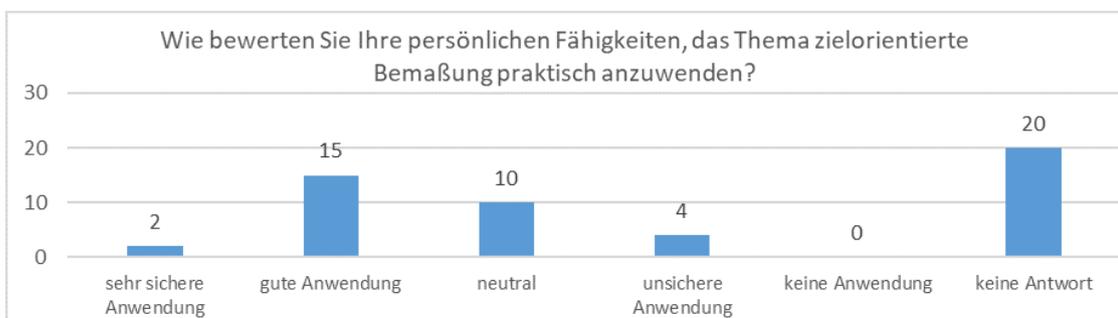


Abbildung E.18: Einschätzung der persönlichen Fähigkeiten zum Thema zielorientierte Bemaßung

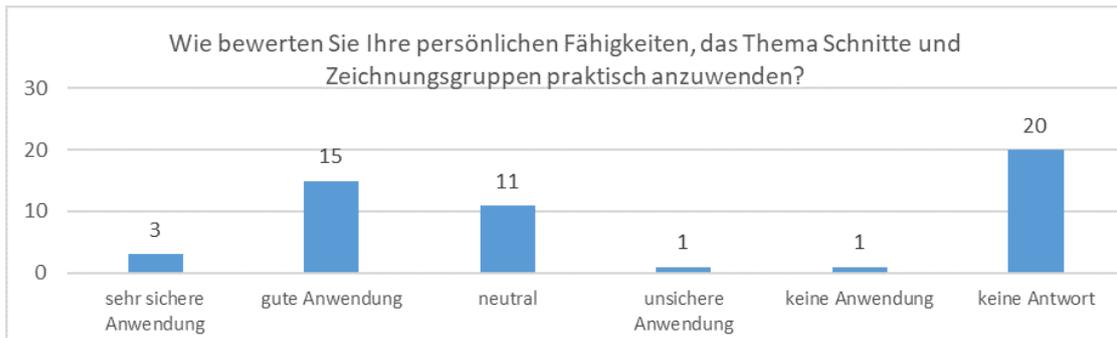


Abbildung E.19: Einschätzung der persönlichen Fähigkeiten zum Thema Schnitte und Zeichnungsgruppen

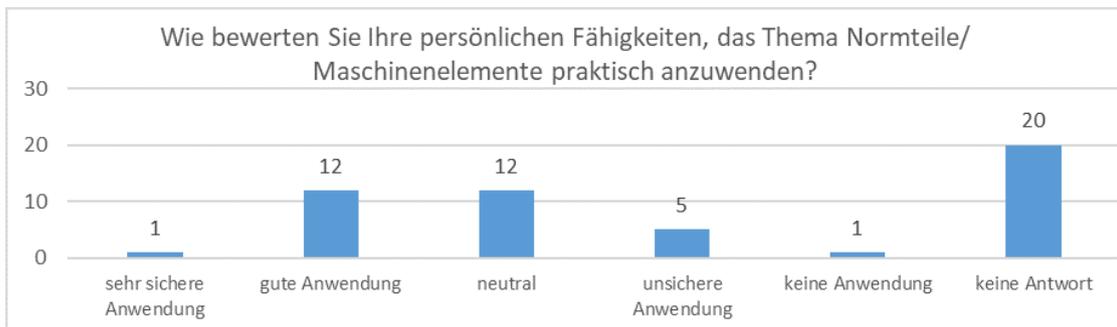


Abbildung E.20: Einschätzung der persönlichen Fähigkeiten zum Thema Normteile und Maschinenelemente

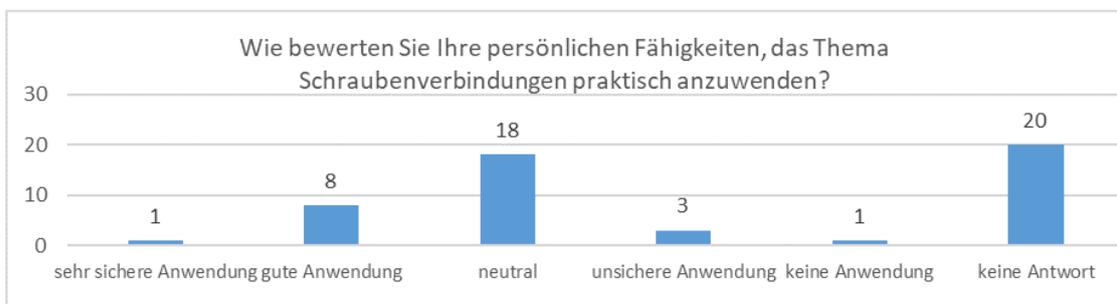


Abbildung E.21: Einschätzung der persönlichen Fähigkeiten zum Thema Schraubenverbindungen

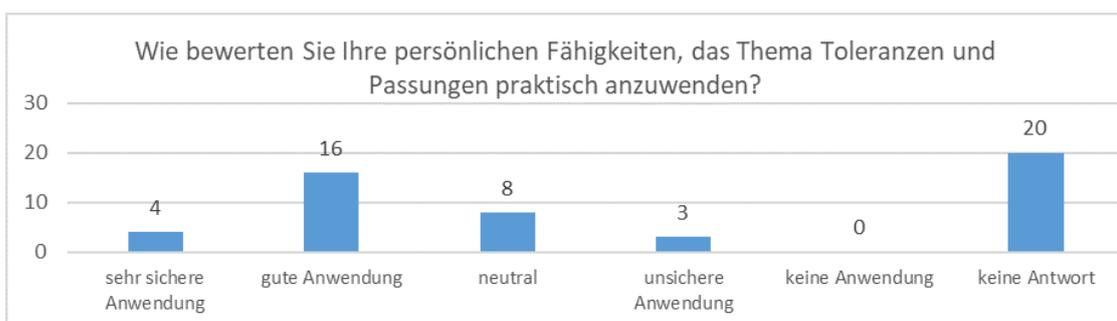


Abbildung E.22: Einschätzung der persönlichen Fähigkeiten zum Thema Toleranzen und Passungen

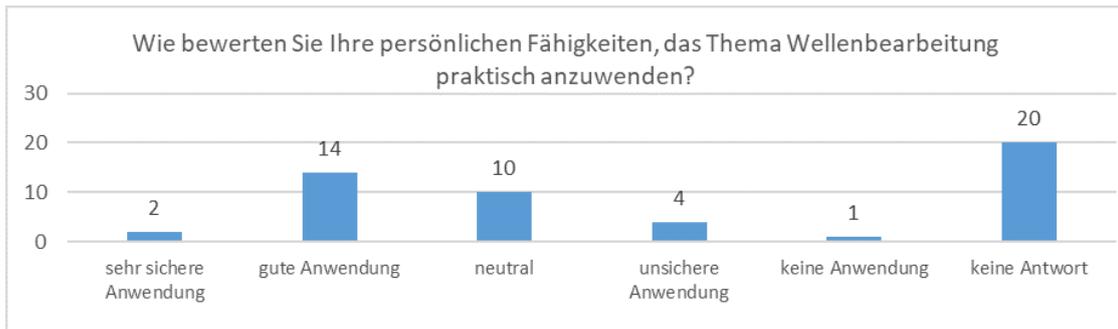


Abbildung E.23: Einschätzung der persönlichen Fähigkeiten zum Thema Wellenbearbeitung

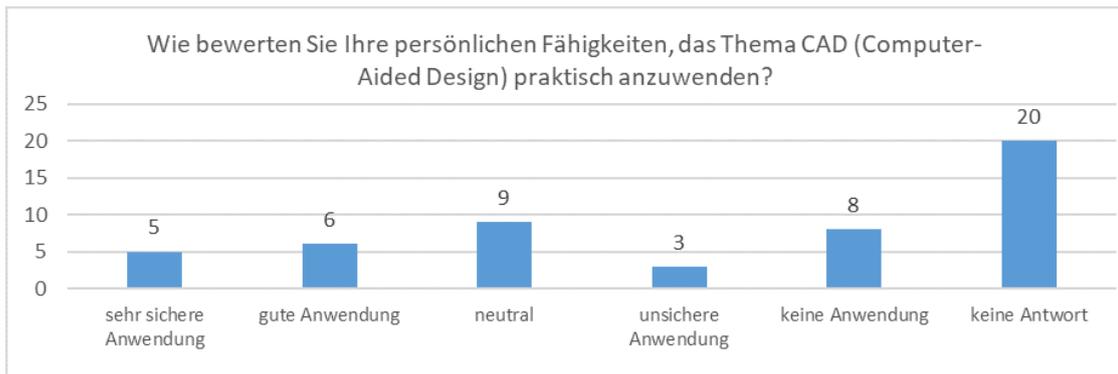
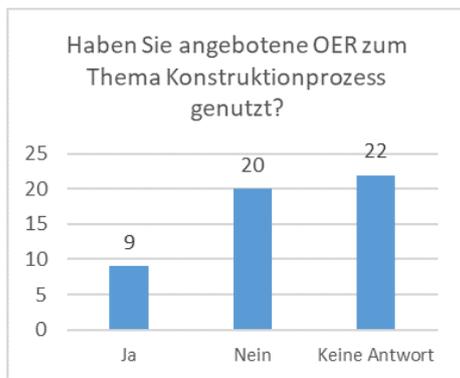
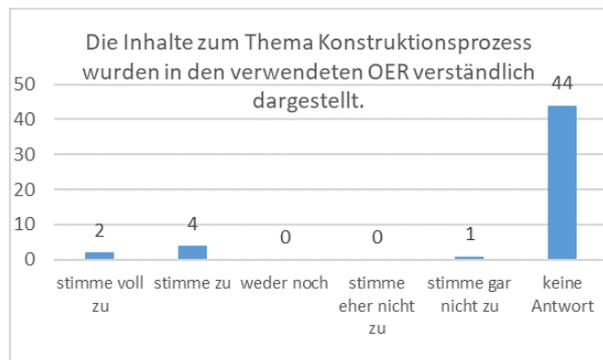


Abbildung E.24: Einschätzung der persönlichen Fähigkeiten zum Thema CAD

### Thema Konstruktionsprozess



(a)



(b)

Abbildung E.25: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Konstruktionsprozess

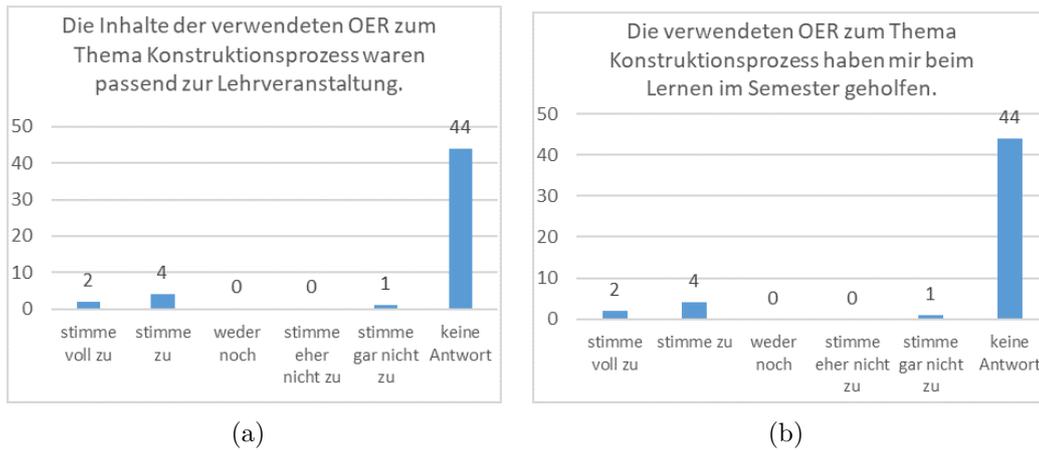


Abbildung E.26: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Konstruktionsprozess

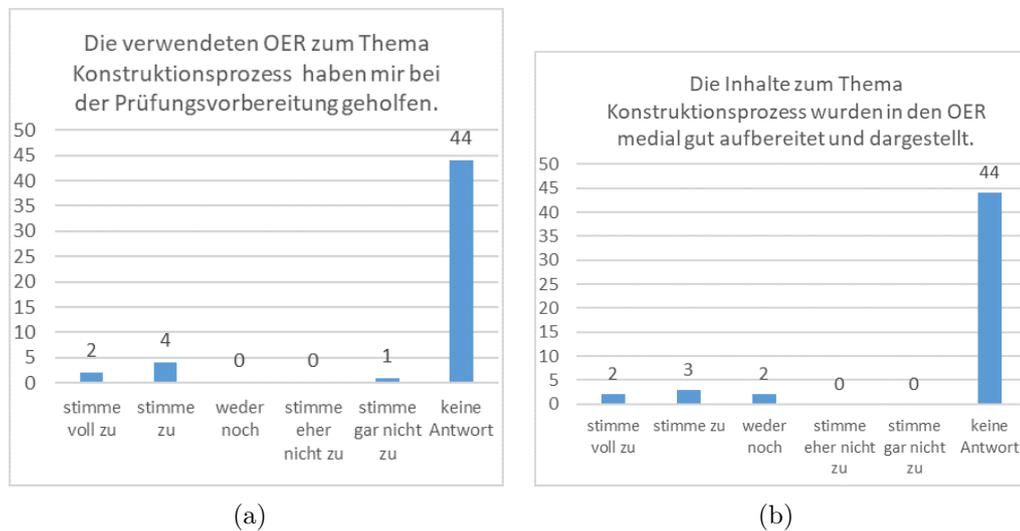


Abbildung E.27: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Konstruktionsprozess

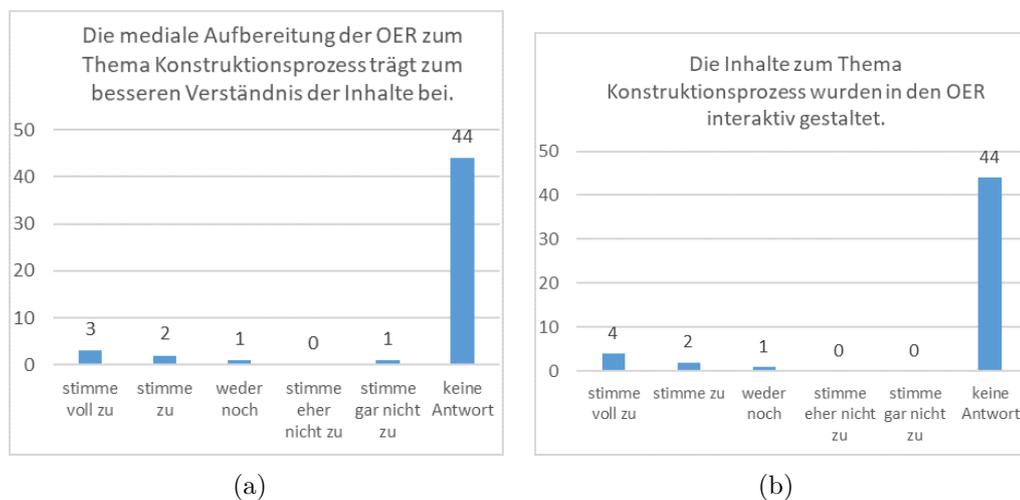


Abbildung E.28: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Konstruktionsprozess

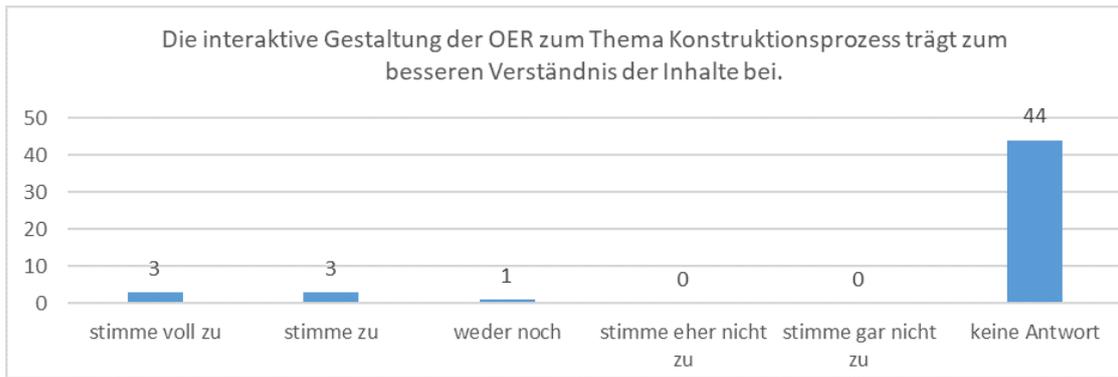


Abbildung E.29: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Konstruktionsprozess

### Thema Erstellen von Freihandzeichnungen

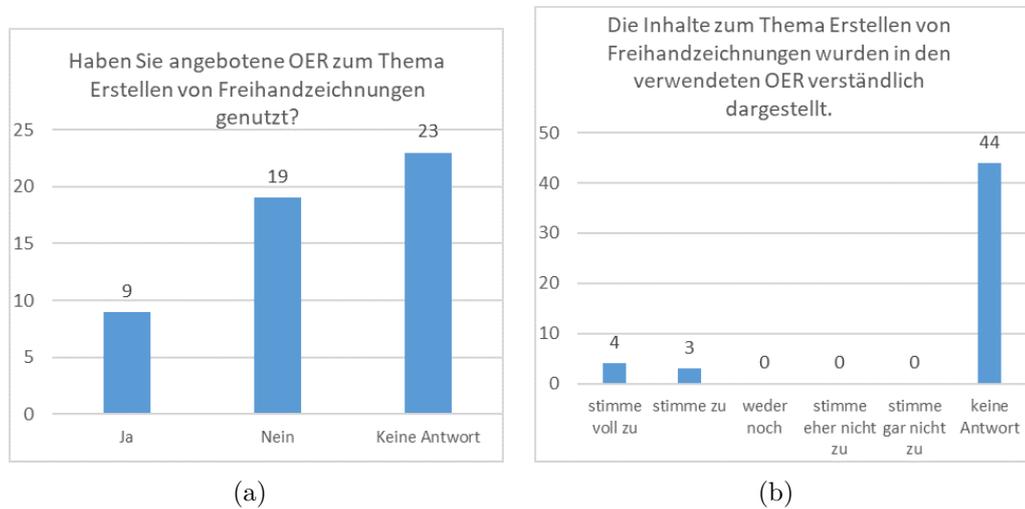


Abbildung E.30: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Erstellen von Freihandzeichnungen

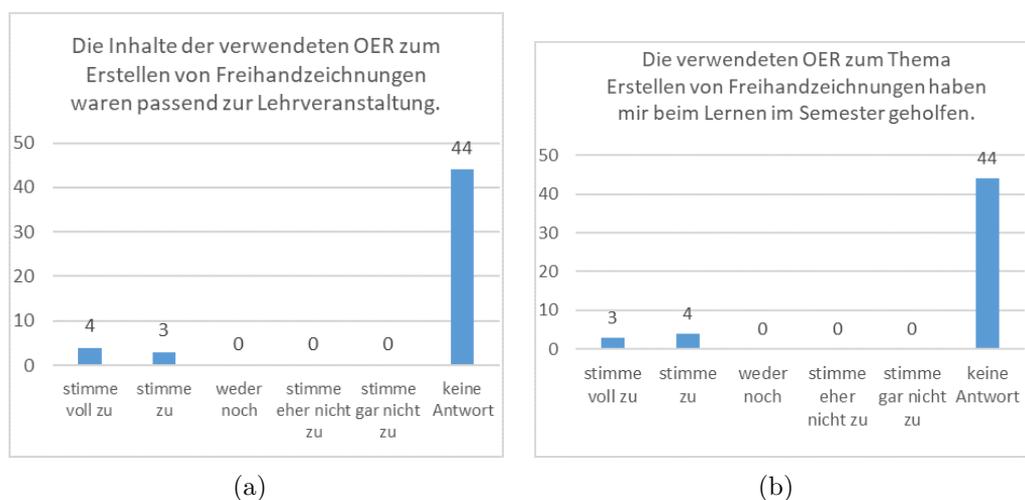


Abbildung E.31: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Erstellen von Freihandzeichnungen

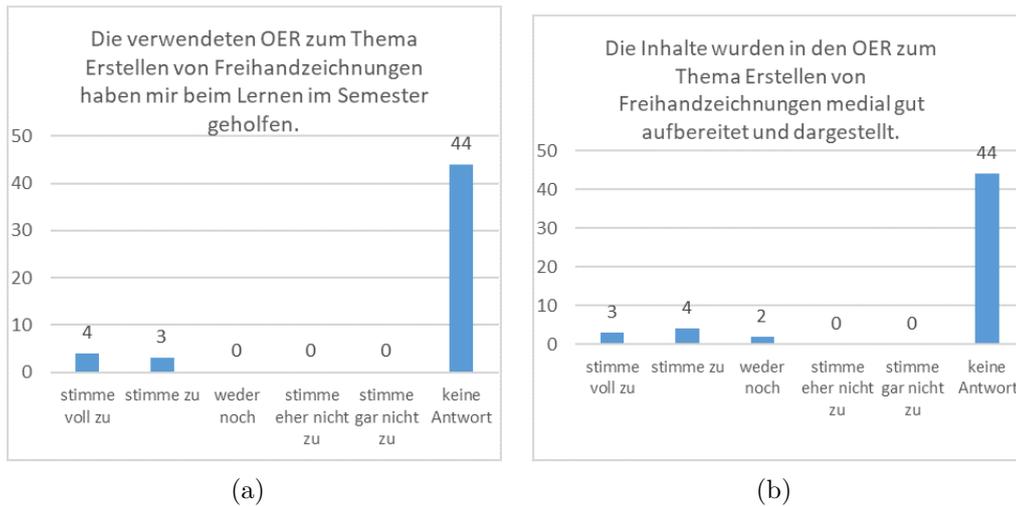


Abbildung E.32: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Erstellen von Freihandzeichnungen

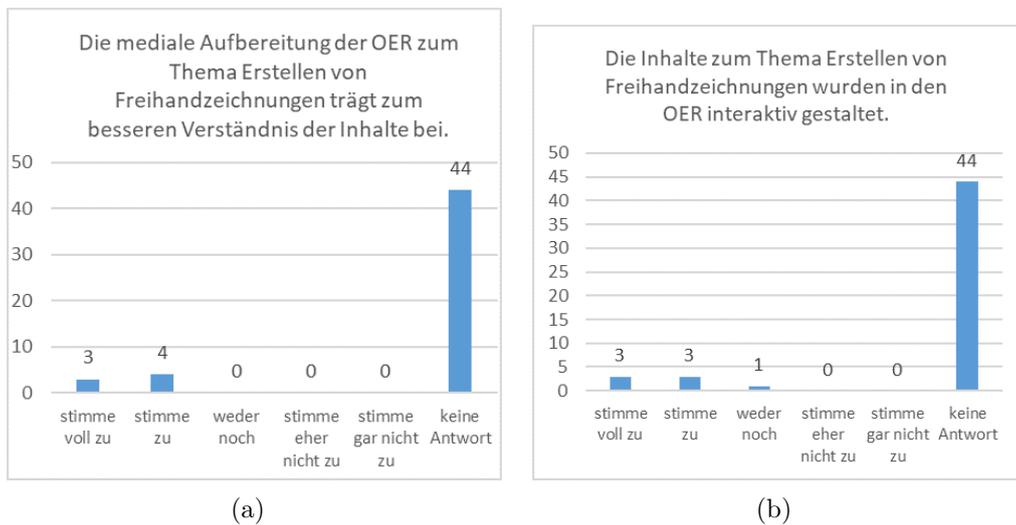


Abbildung E.33: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Erstellen von Freihandzeichnungen

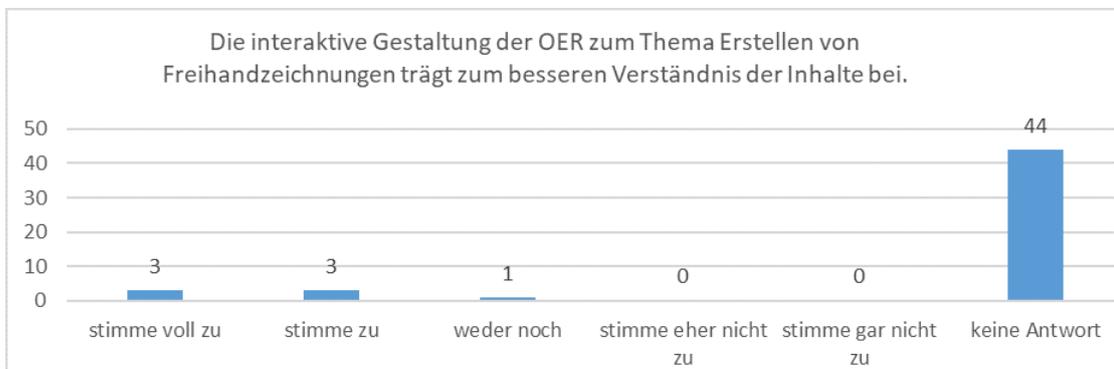


Abbildung E.34: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Erstellen von Freihandzeichnungen

Thema GPS

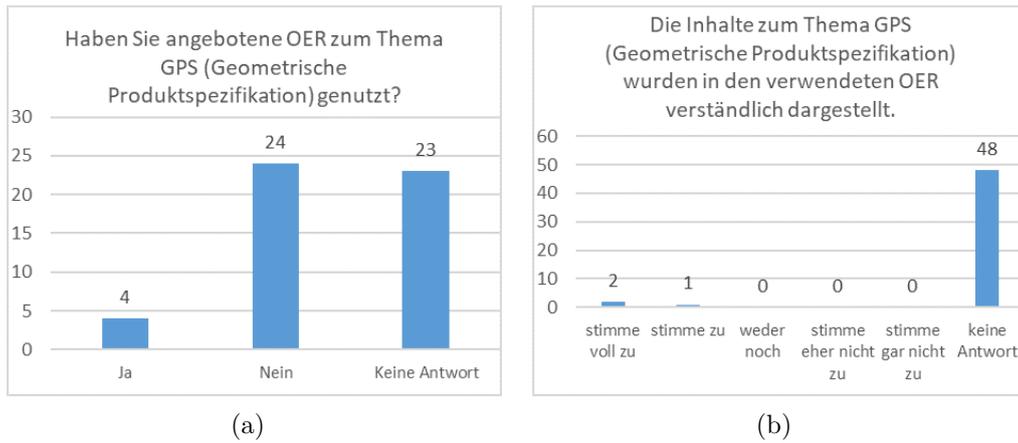


Abbildung E.35: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema GPS

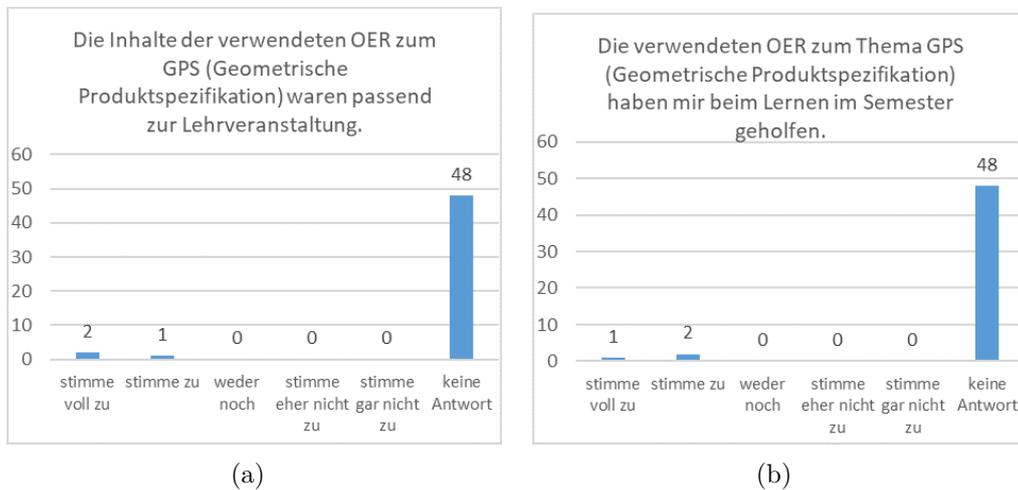


Abbildung E.36: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema GPS

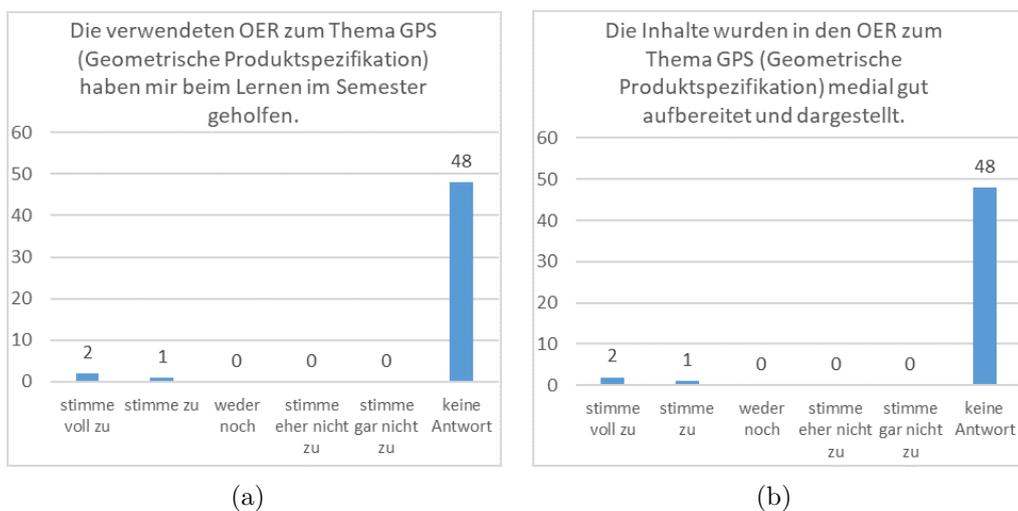


Abbildung E.37: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema GPS

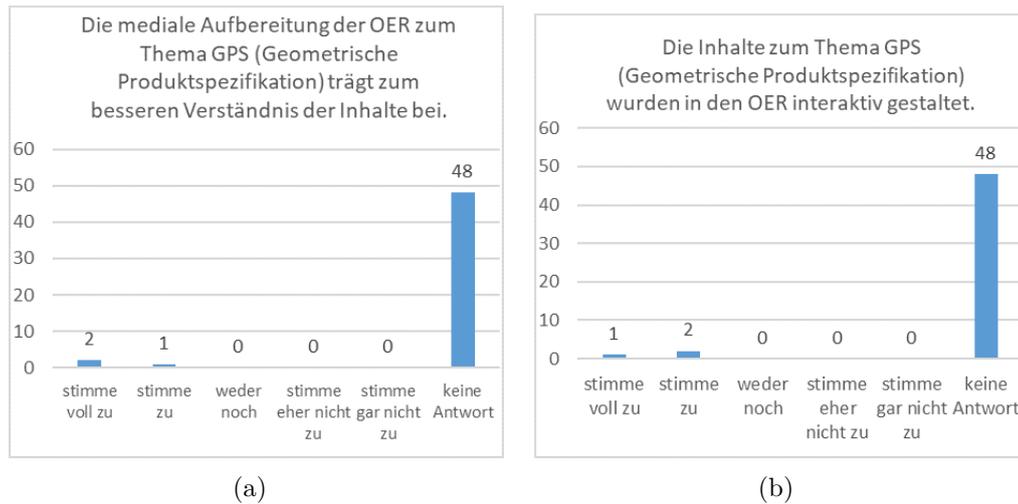


Abbildung E.38: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema GPS

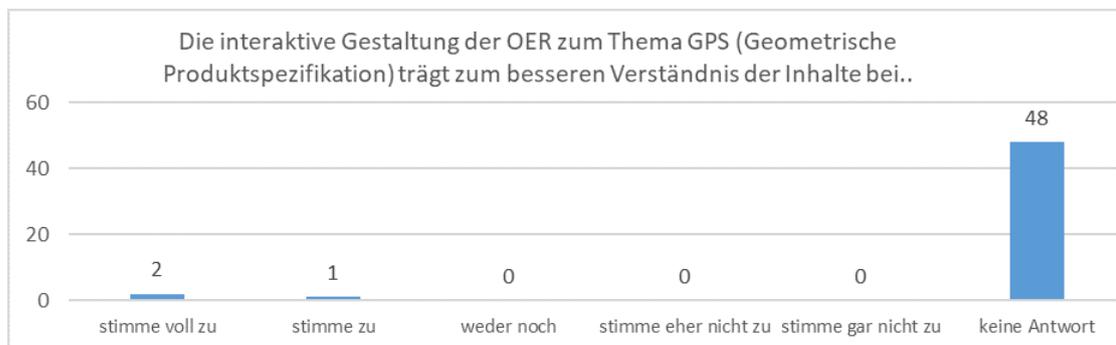


Abbildung E.39: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema GPS

### Thema zielorientierte Bemaßung

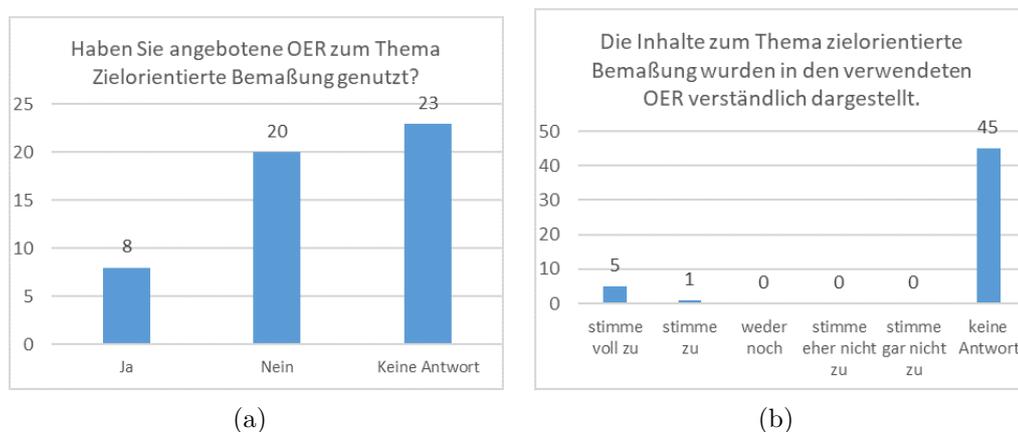


Abbildung E.40: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema zielorientierte Bemaßung

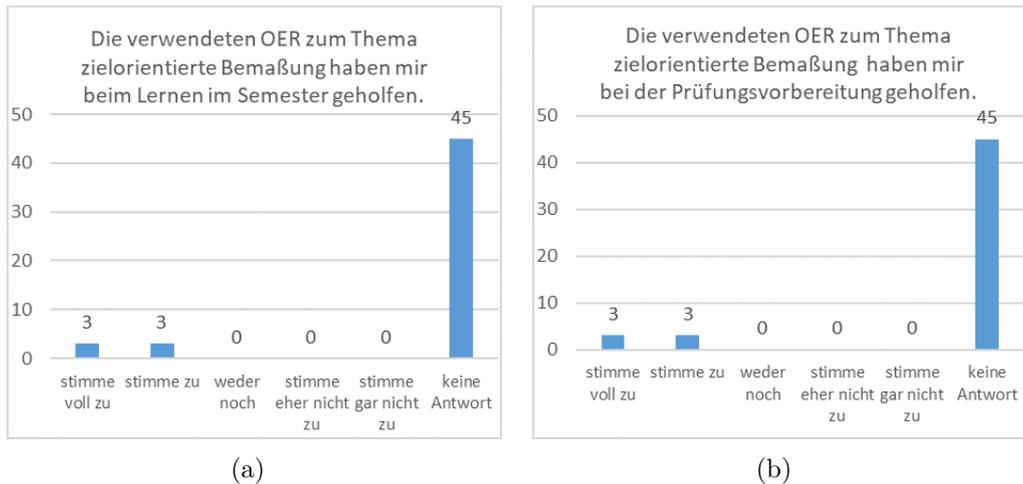


Abbildung E.41: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema zielorientierte Bemaßung

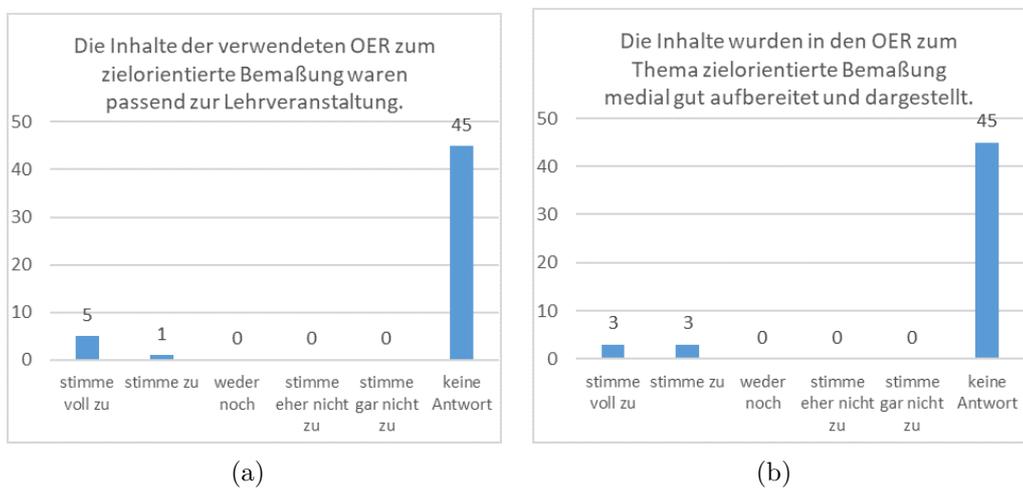


Abbildung E.42: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema zielorientierte Bemaßung

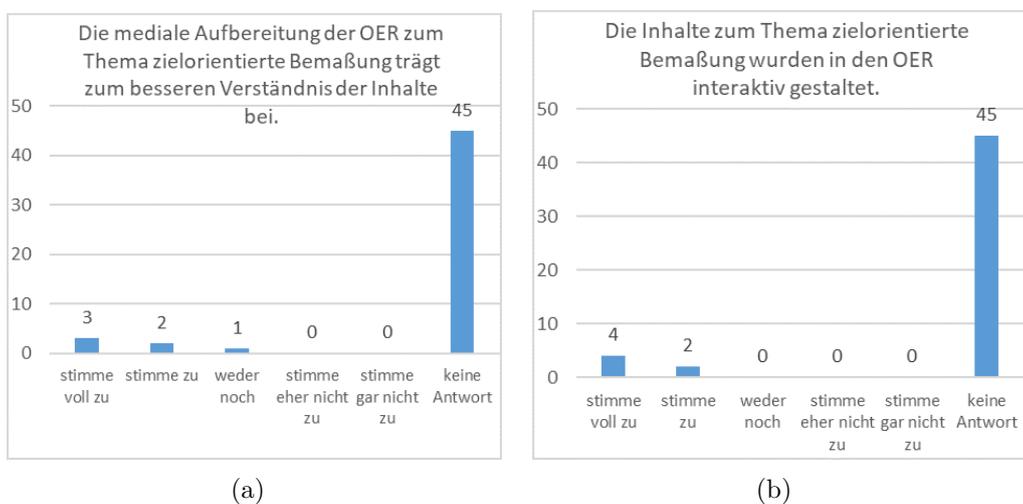


Abbildung E.43: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema zielorientierte Bemaßung

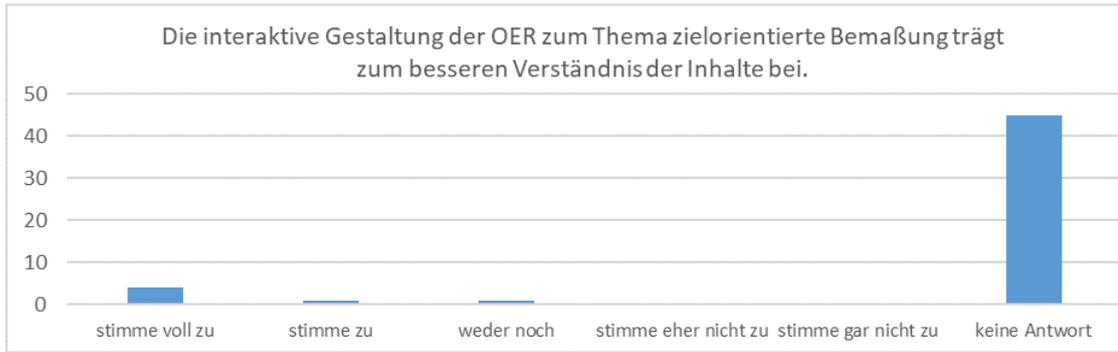
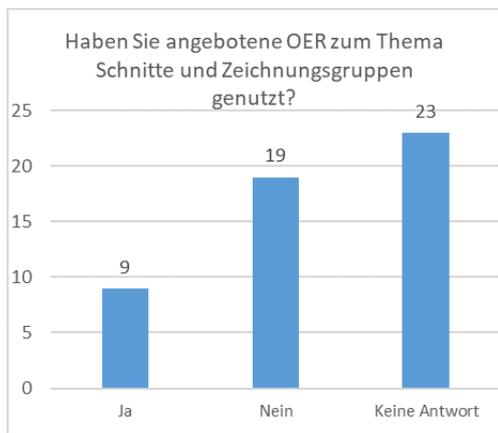
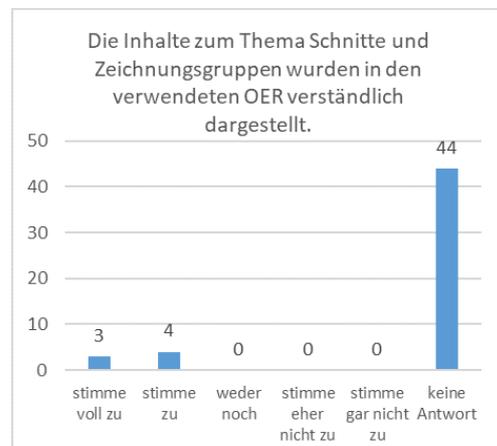


Abbildung E.44: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema zielorientierte Bemaßung

### Thema Schnitte und Zeichnungsgruppen

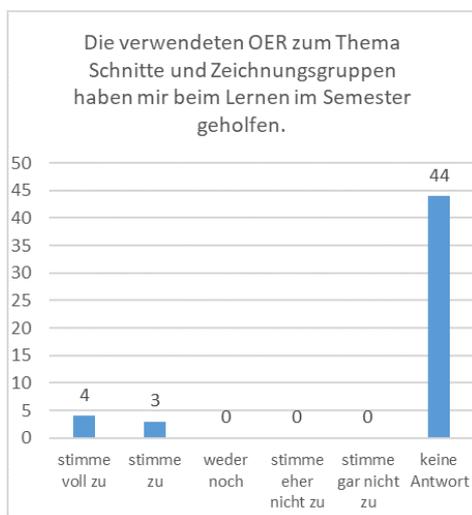


(a)

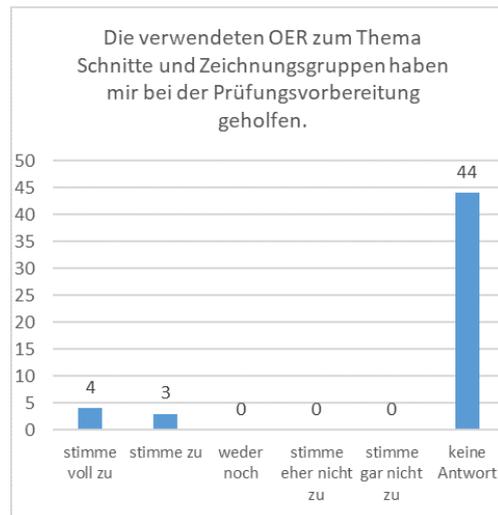


(b)

Abbildung E.45: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Schnitte und Zeichnungsgruppen



(a)



(b)

Abbildung E.46: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Schnitte und Zeichnungsgruppen

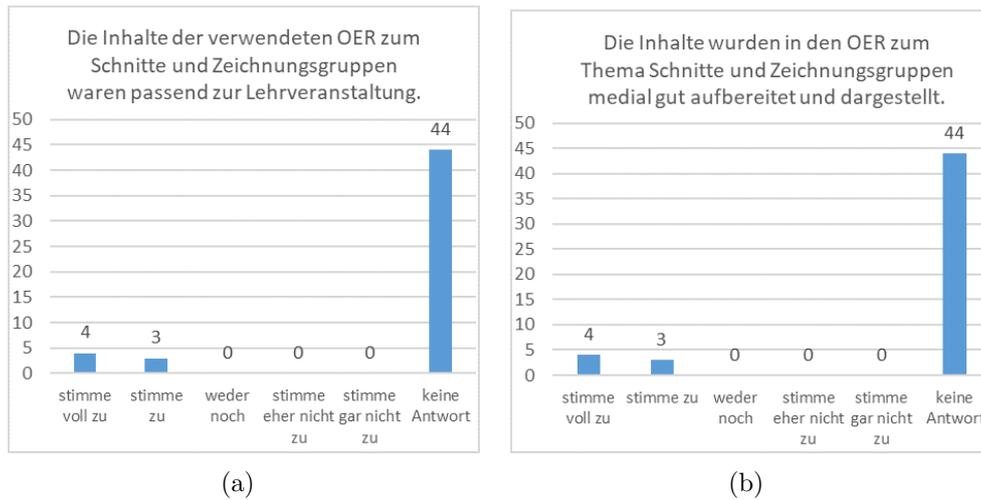


Abbildung E.47: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Schnitte und Zeichnungsgruppen

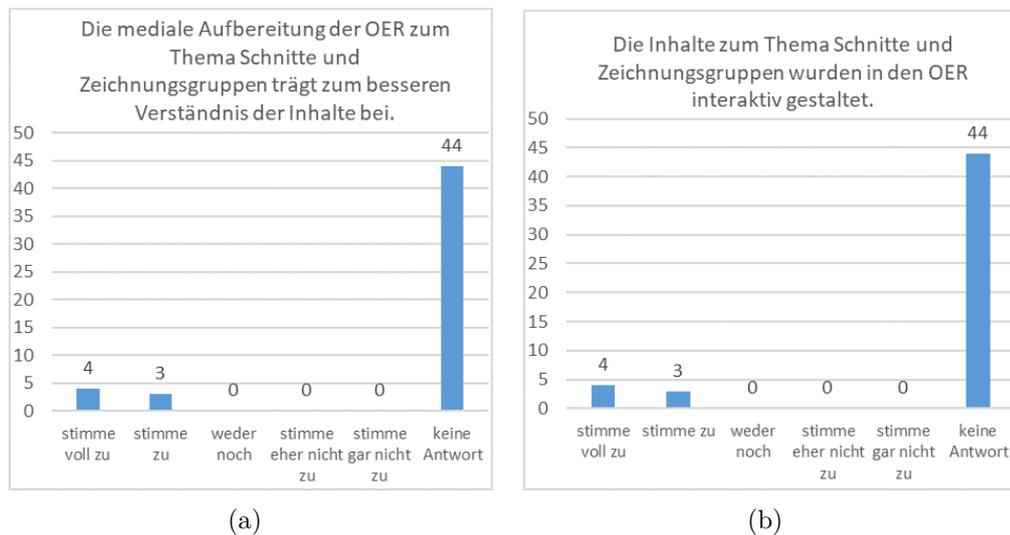


Abbildung E.48: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Schnitte und Zeichnungsgruppen

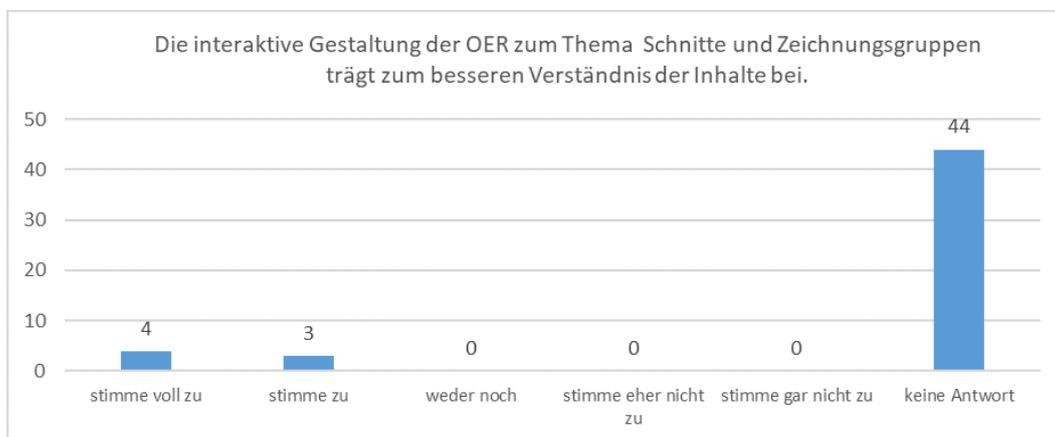


Abbildung E.49: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Schnitte und Zeichnungsgruppen

**Thema Normteile und Maschinenelemente**

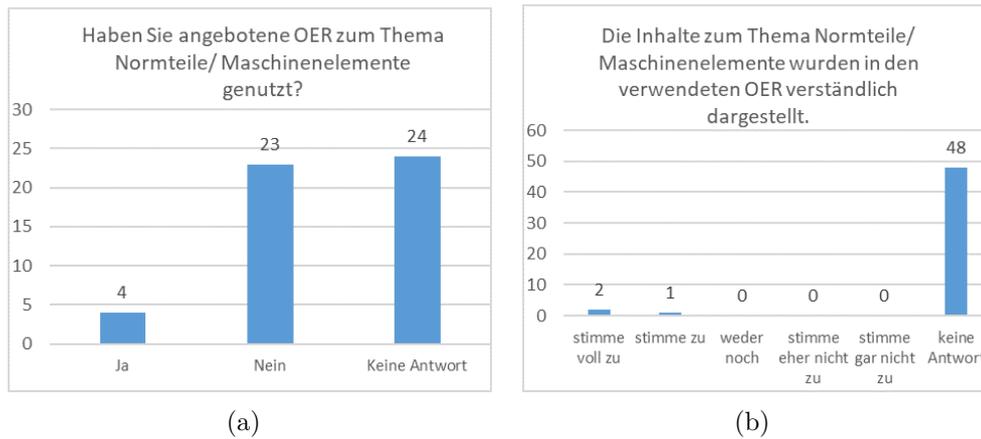


Abbildung E.50: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Normteile und Maschinenelemente

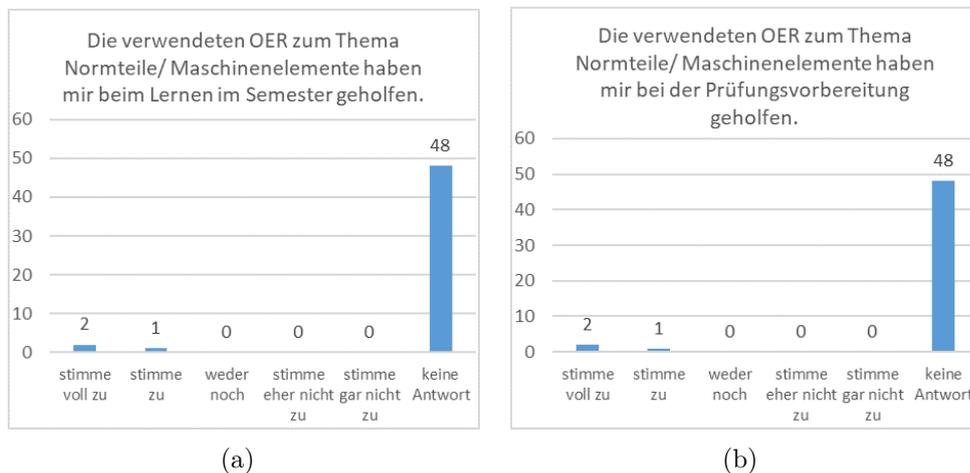


Abbildung E.51: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Normteile und Maschinenelemente

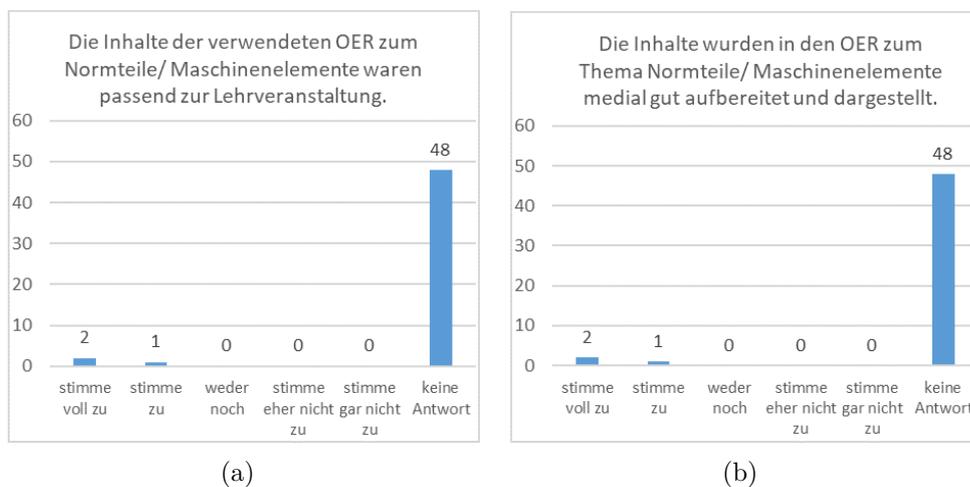


Abbildung E.52: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Normteile und Maschinenelemente

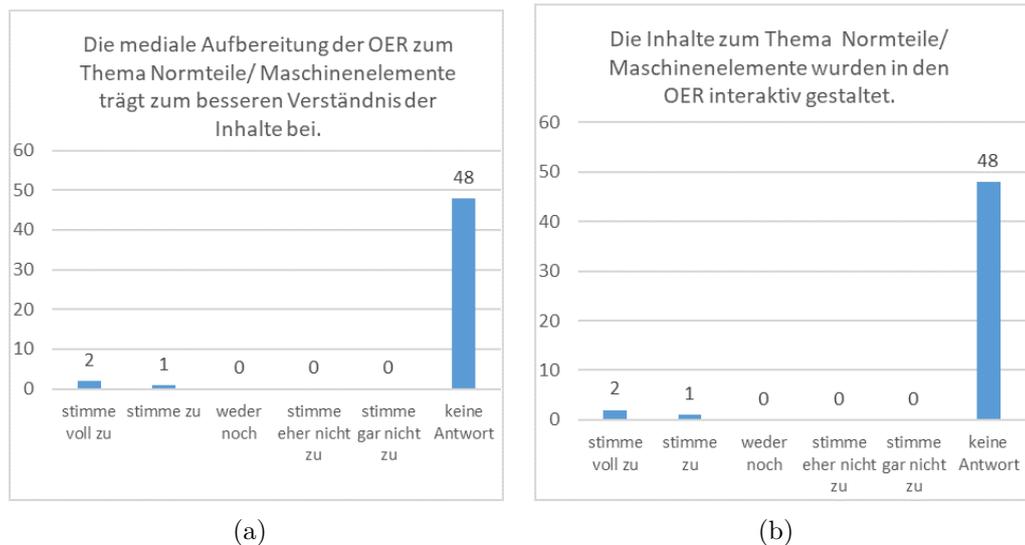


Abbildung E.53: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Normteile und Maschinenelemente

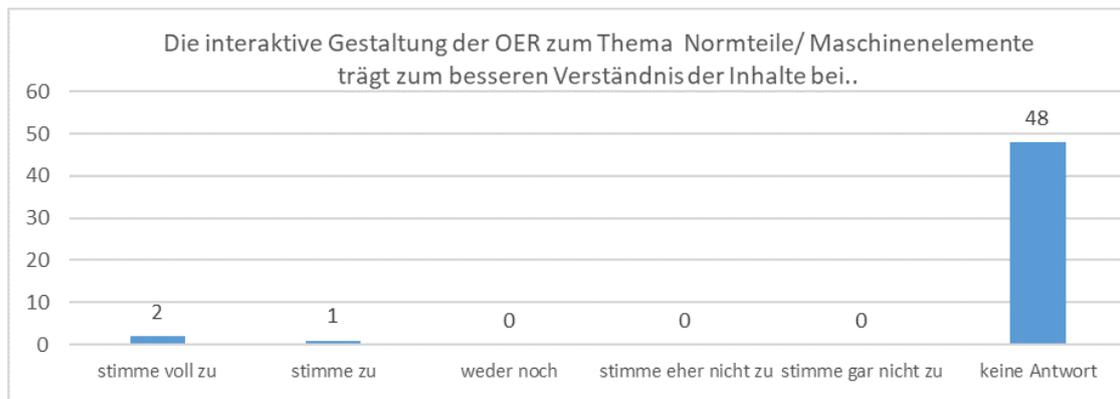


Abbildung E.54: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Normteile und Maschinenelemente

### Thema Schraubenverbindungen

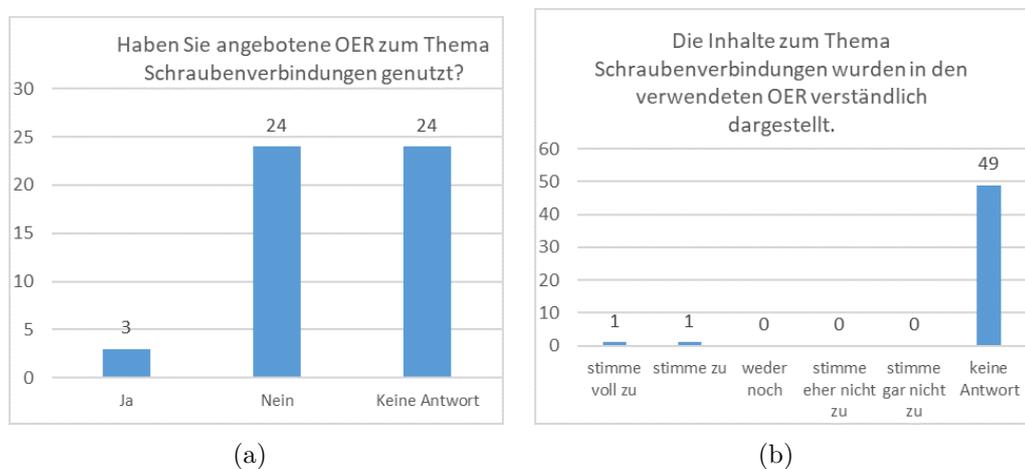


Abbildung E.55: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Schraubenverbindungen

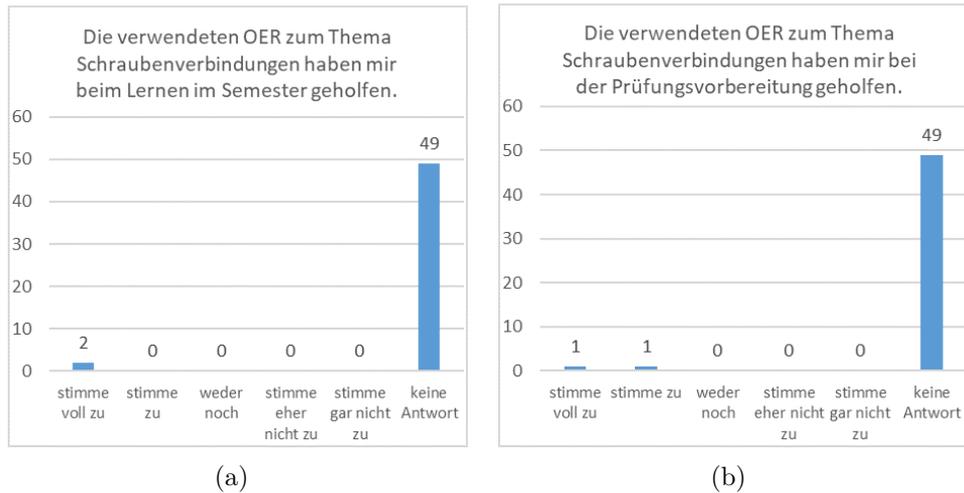


Abbildung E.56: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Schraubenverbindungen

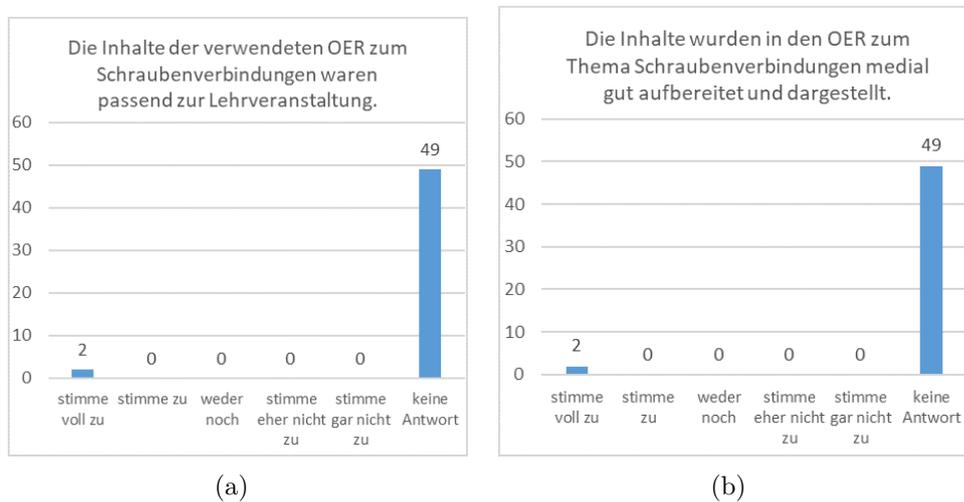


Abbildung E.57: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Schraubenverbindungen

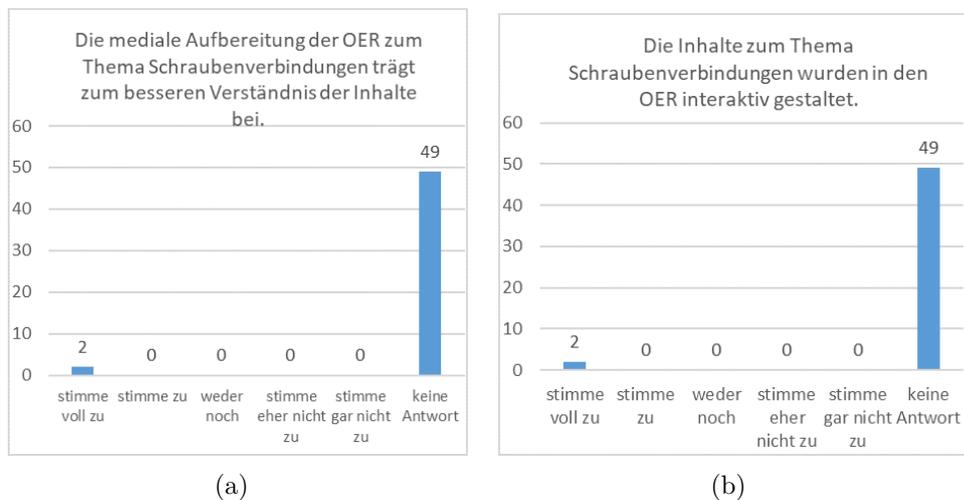


Abbildung E.58: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Schraubenverbindungen

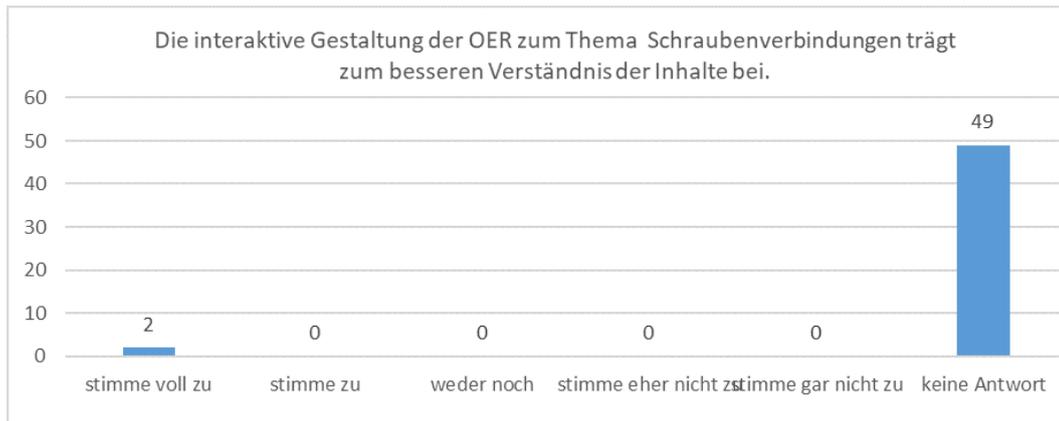


Abbildung E.59: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Schraubenverbindungen

### Thema Toleranzen und Passungen

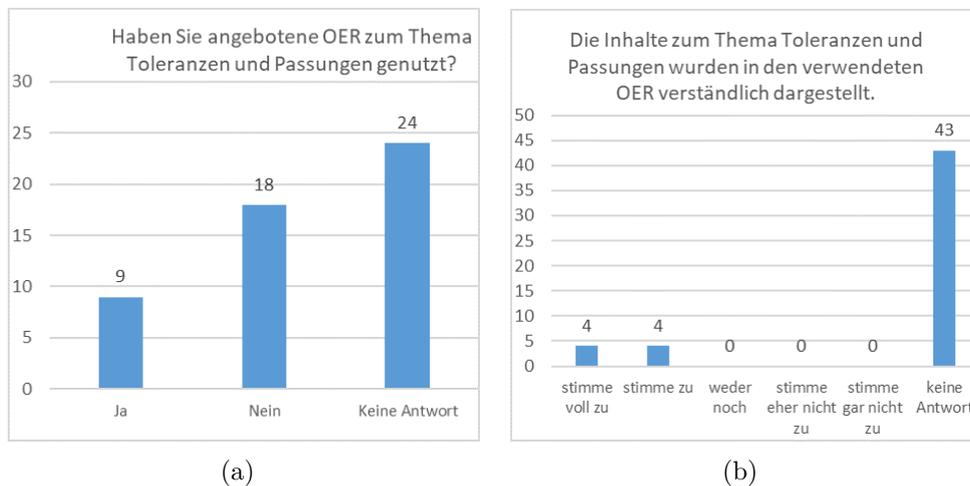


Abbildung E.60: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Toleranzen und Passungen

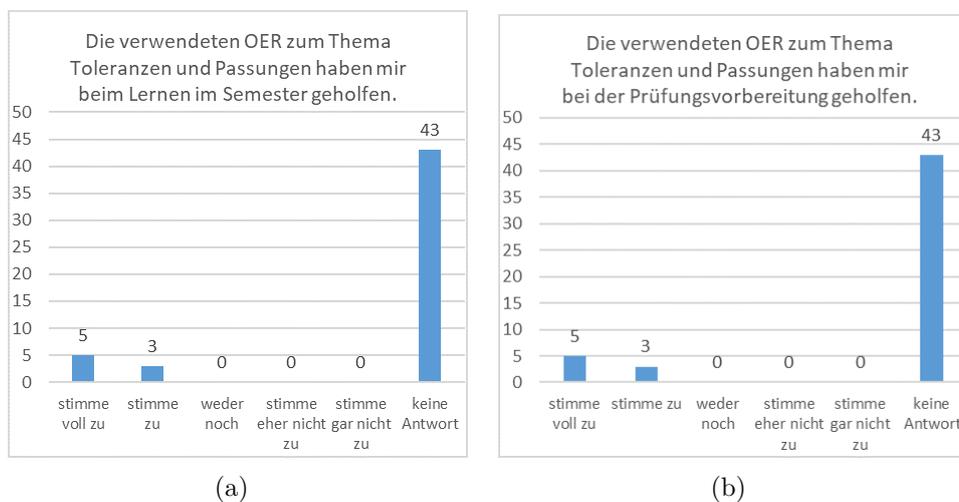


Abbildung E.61: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Toleranzen und Passungen

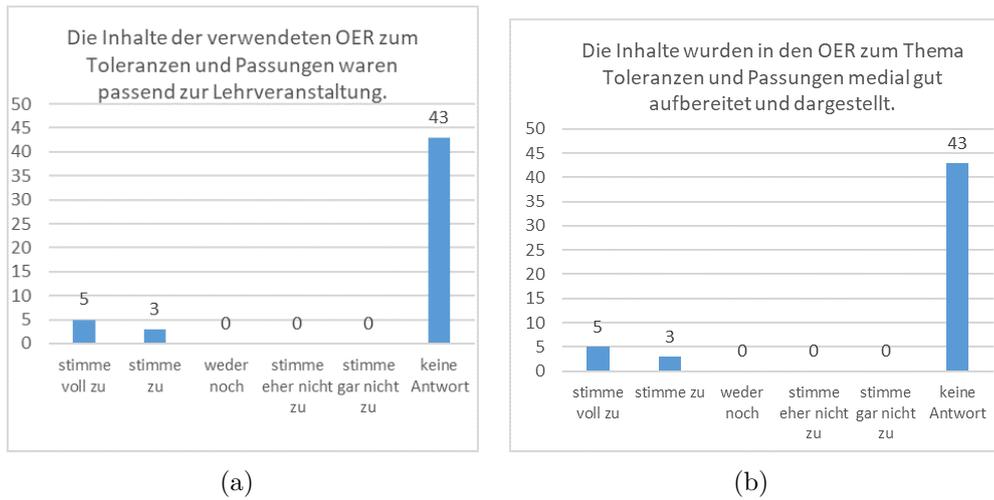


Abbildung E.62: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Toleranzen und Passungen

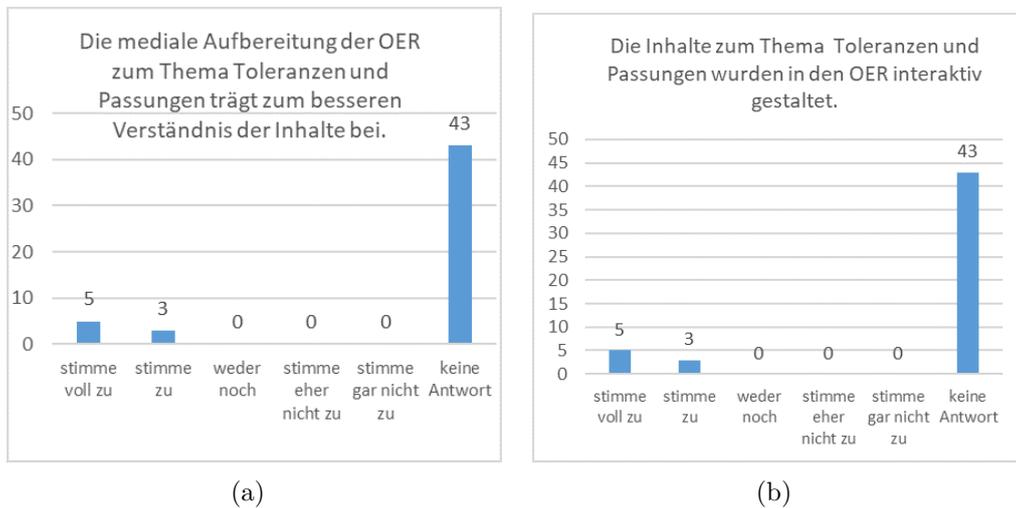


Abbildung E.63: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Toleranzen und Passungen

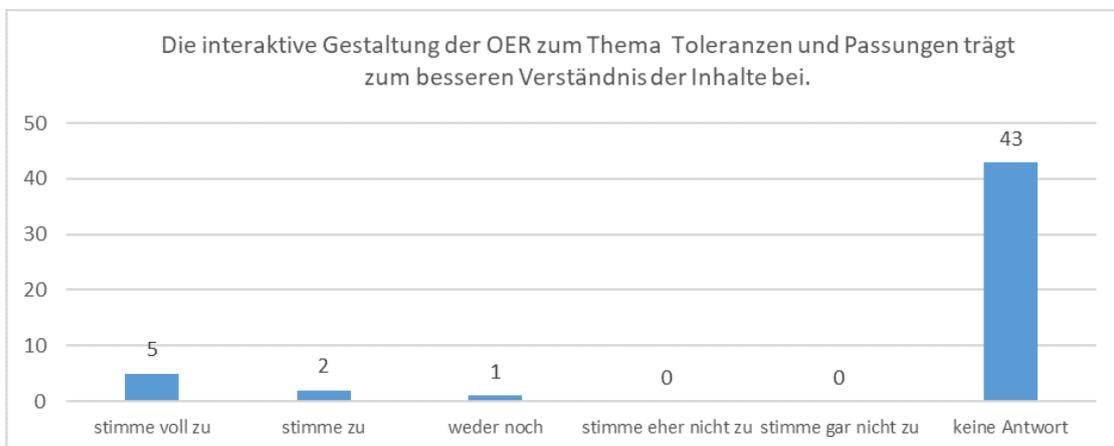


Abbildung E.64: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Toleranzen und Passungen

**Thema Wellenbearbeitung**

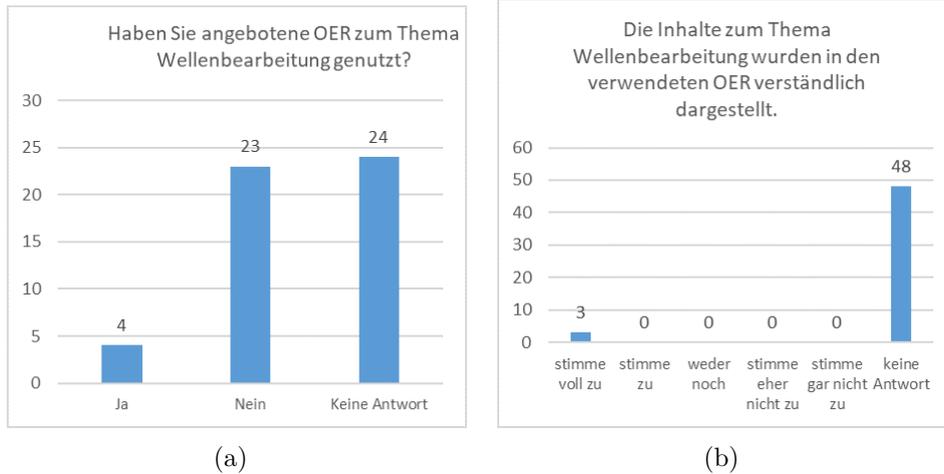


Abbildung E.65: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema Wellenbearbeitung

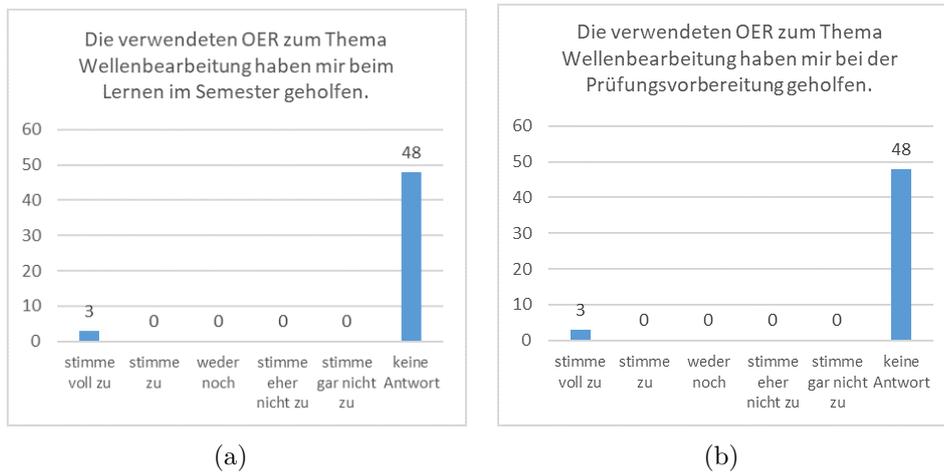


Abbildung E.66: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema Wellenbearbeitung

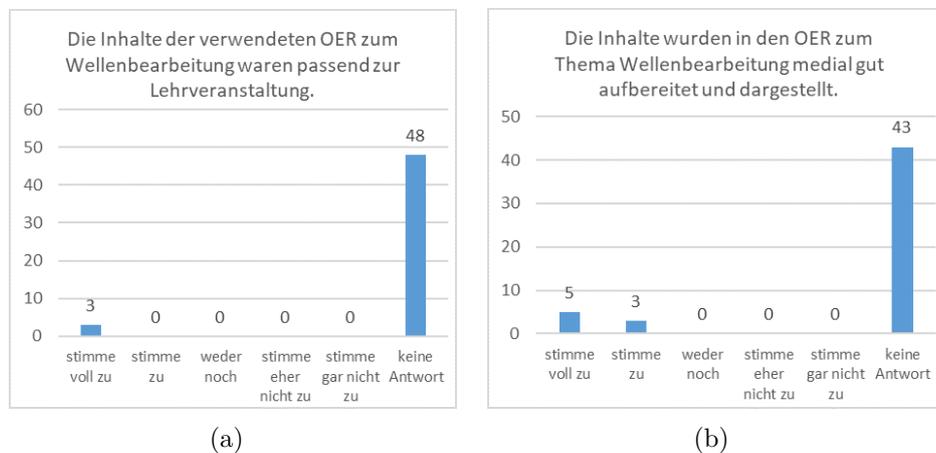


Abbildung E.67: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema Wellenbearbeitung

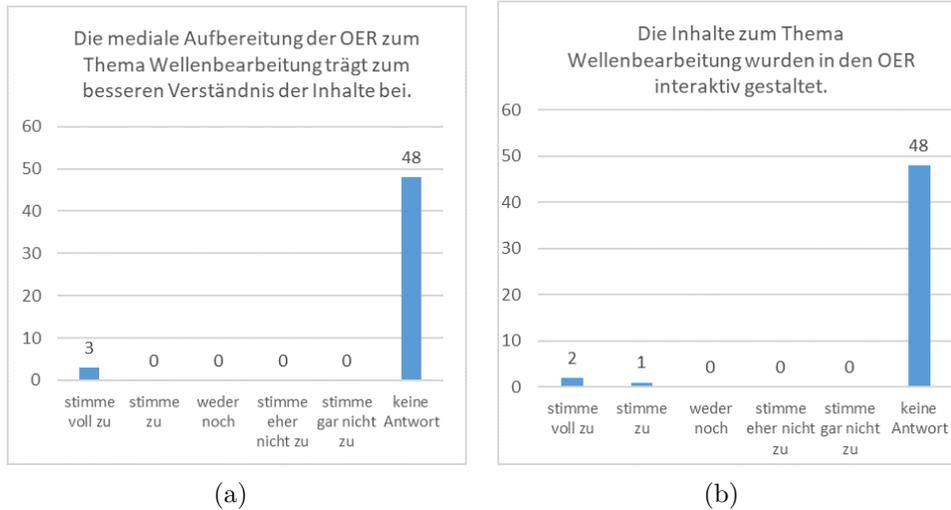


Abbildung E.68: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema Wellenbearbeitung

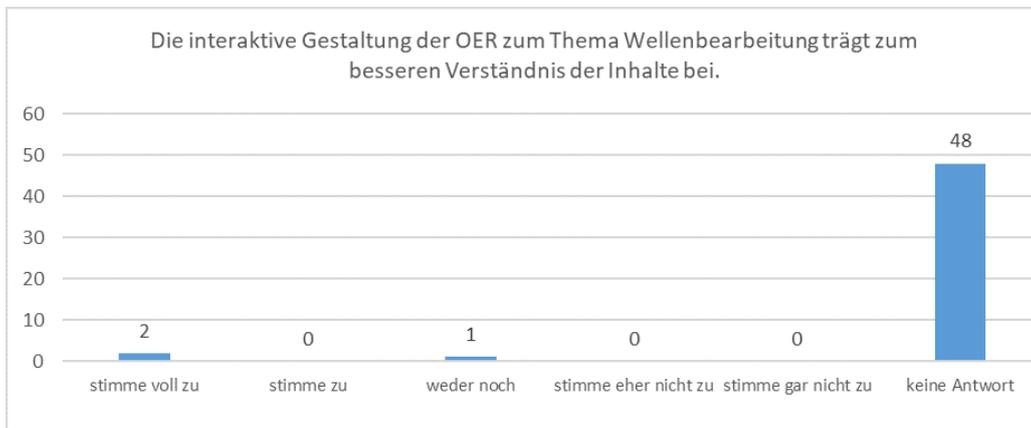


Abbildung E.69: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema Wellenbearbeitung

### Thema CAD

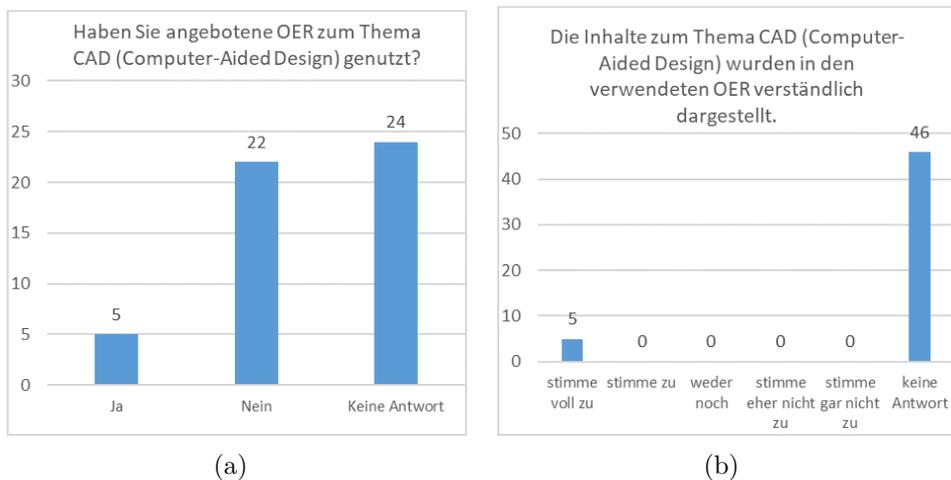


Abbildung E.70: Nutzung der angebotenen OER und Bewertung der Darstellung der angebotenen OER zum Thema CAD

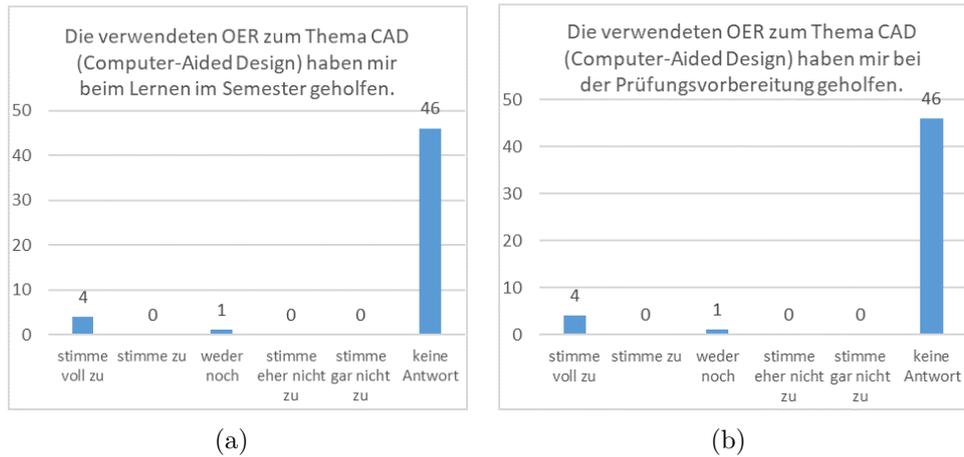


Abbildung E.71: Fachliche Einordnung und Unterstützung beim Lernen der OER zum Thema CAD

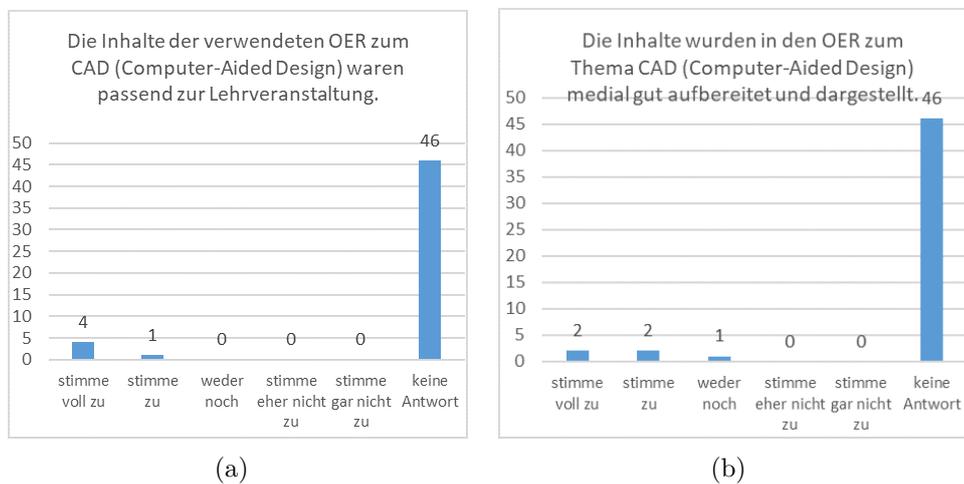


Abbildung E.72: Unterstützung bei der Prüfungsvorbereitung und mediale Aufbereitung der OER zum Thema CAD

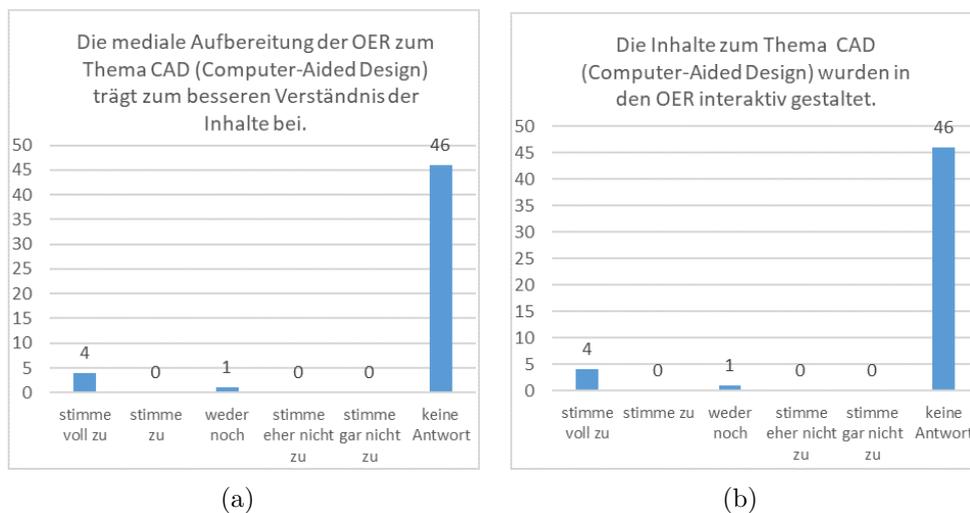


Abbildung E.73: Verständnis durch mediale Aufbereitung und interaktive Gestaltung der OER zum Thema CAD

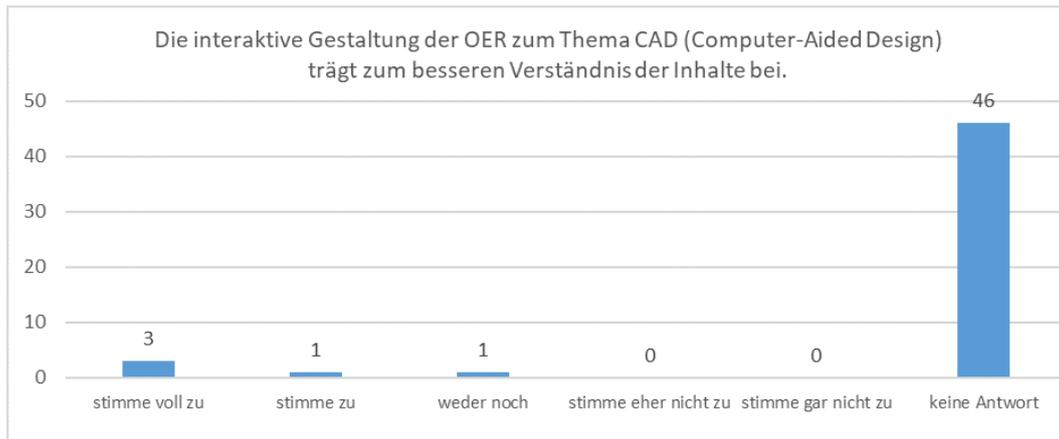


Abbildung E.74: Auswirkungen der Interaktivität der OER auf das Verständnis zum Thema CAD

### OER-Einbindung in die Materialien

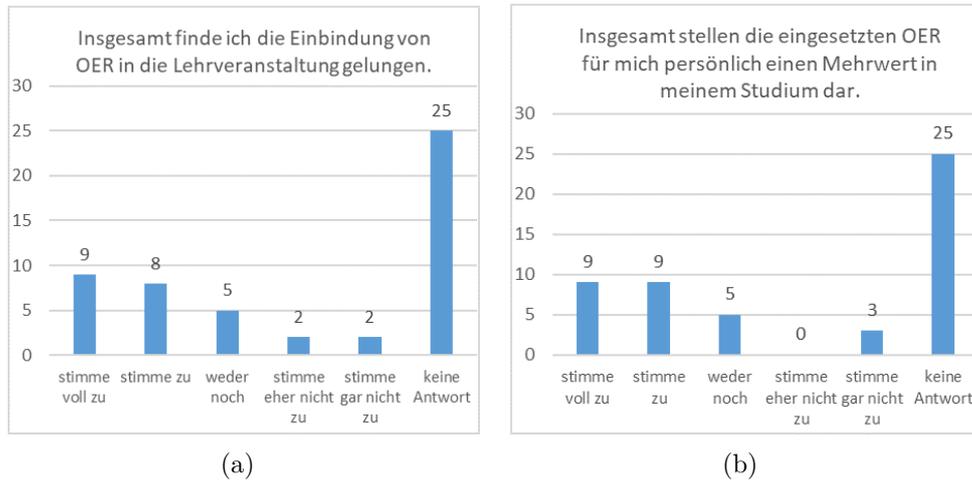


Abbildung E.75: Einbindung OER bezüglich TZ und Mehrwert der OER

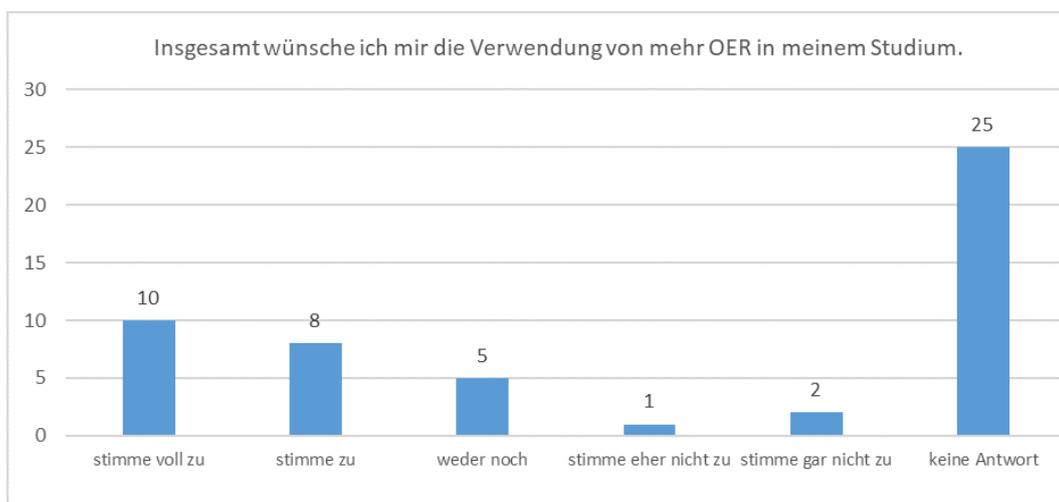


Abbildung E.76: Wunsch nach zusätzlichen OER

# F Analyse der Module an Hochschulen in NRW mit Bezug auf TZ

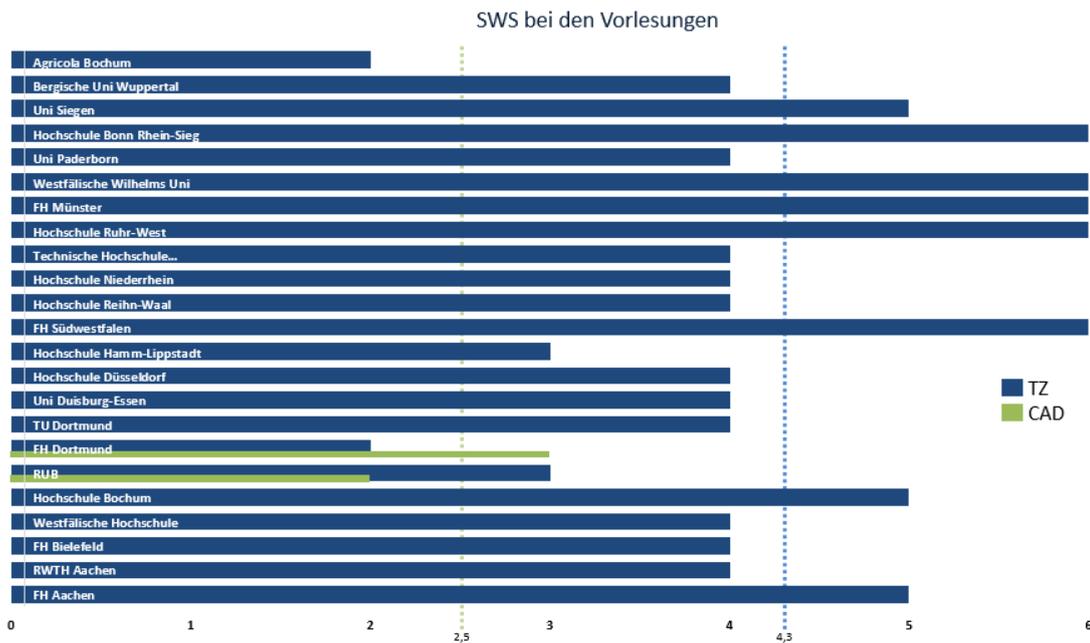


Abbildung F.1: Verteilung der SWS an Hochschulen in NRW bzgl. TZ

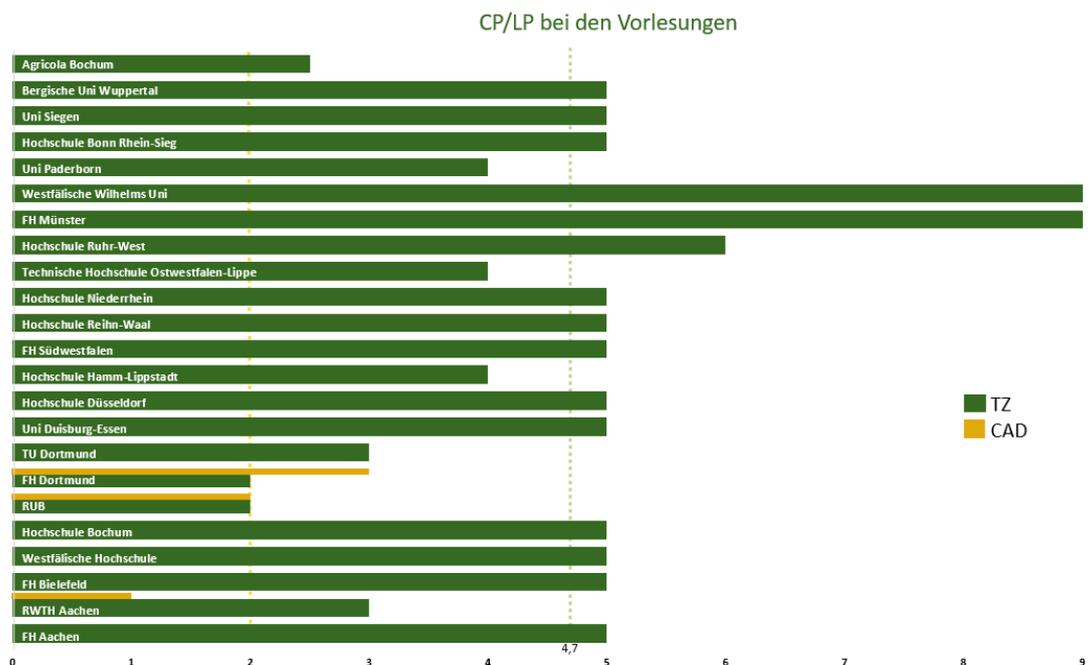


Abbildung F.2: Verteilung der CP/LP an Hochschulen in NRW bzgl. TZ

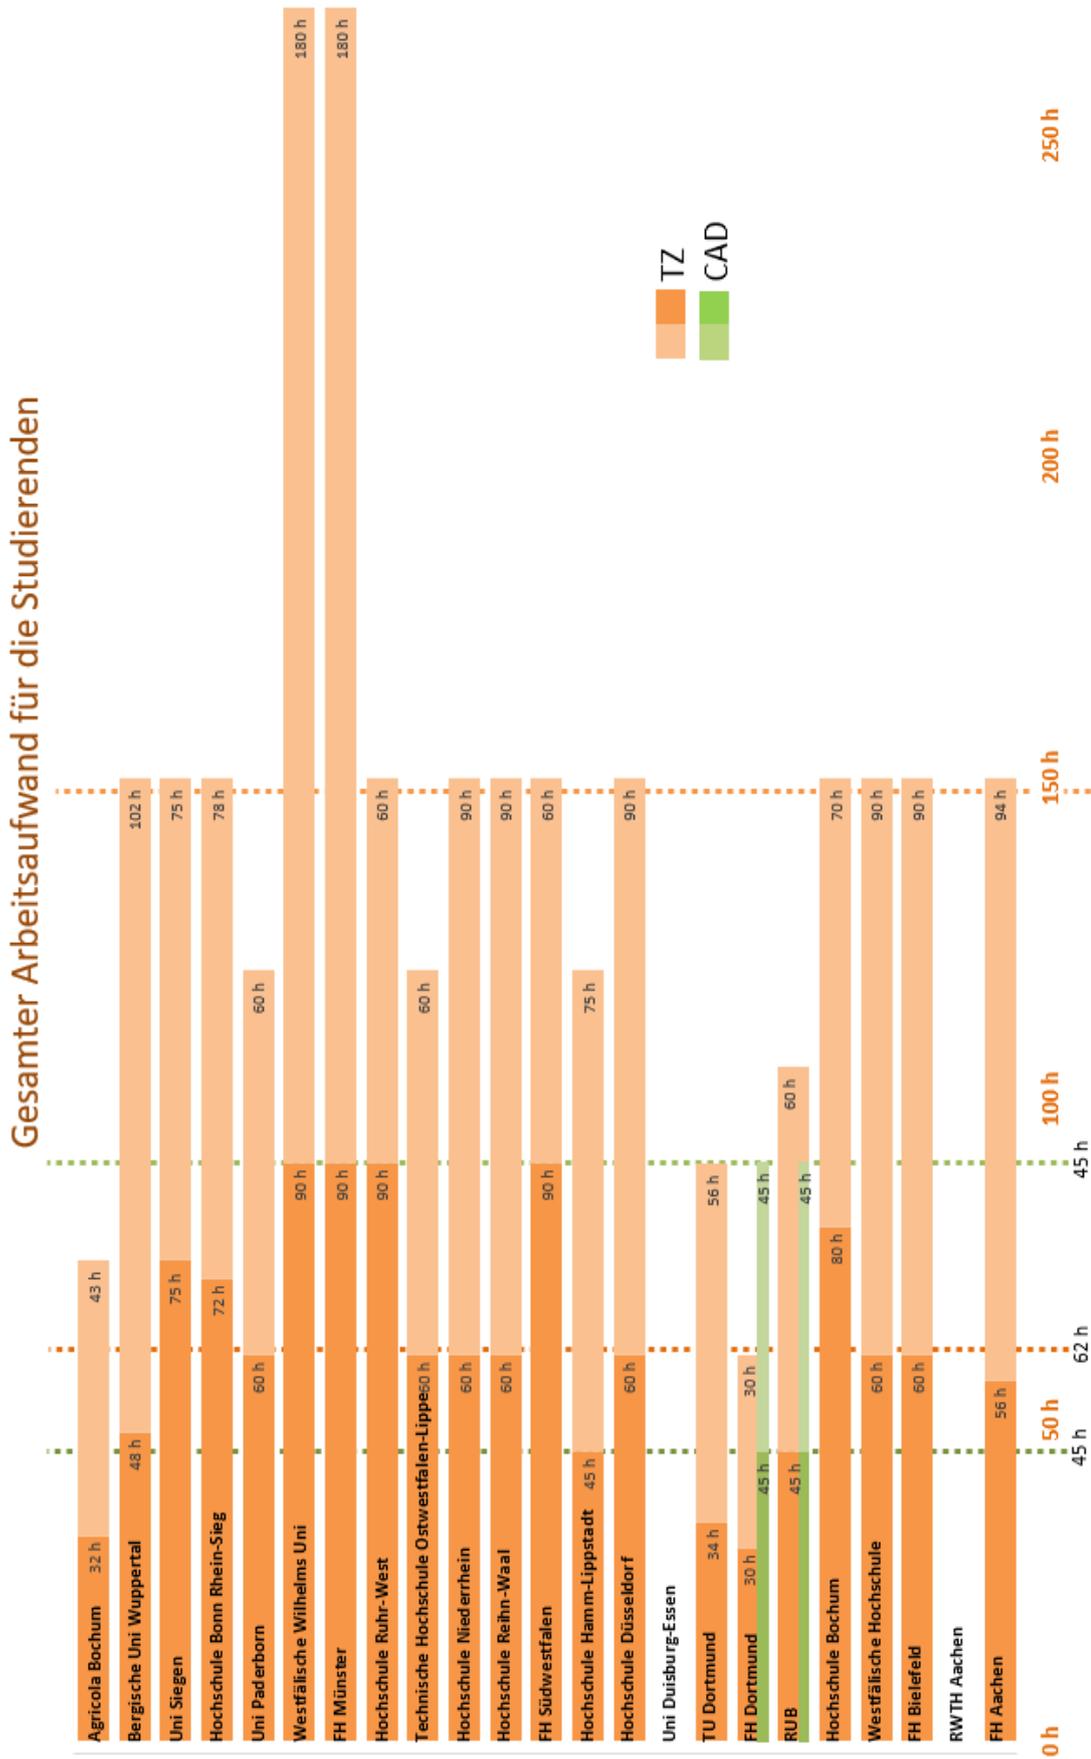


Abbildung F.3: Verteilung des Workloads an Hochschulen in NRW bzgl. TZ

# G Auswertung der ME in NRW

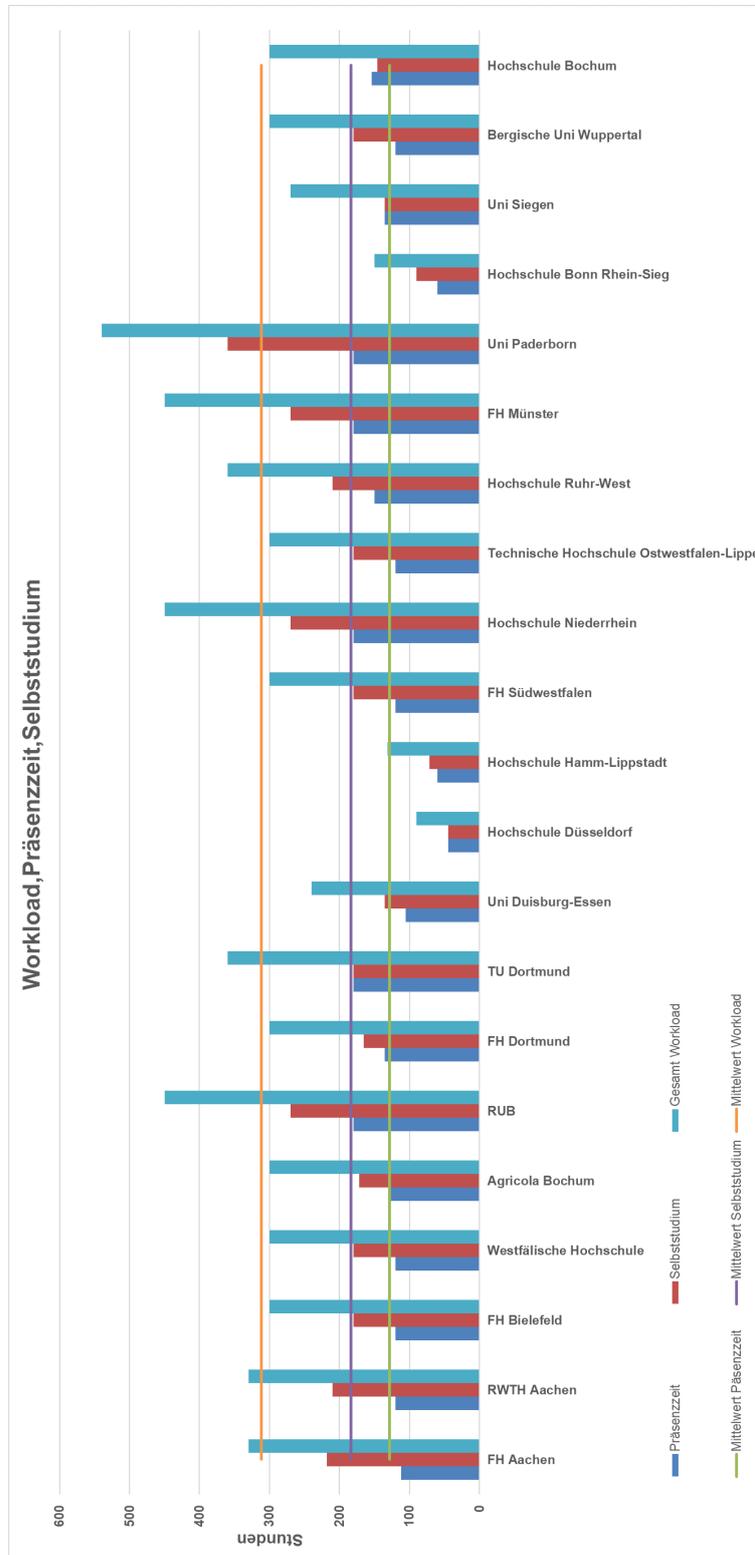


Abbildung G.1: Vergleich des Modulumfangs an den verschiedenen Hochschulen in NRW

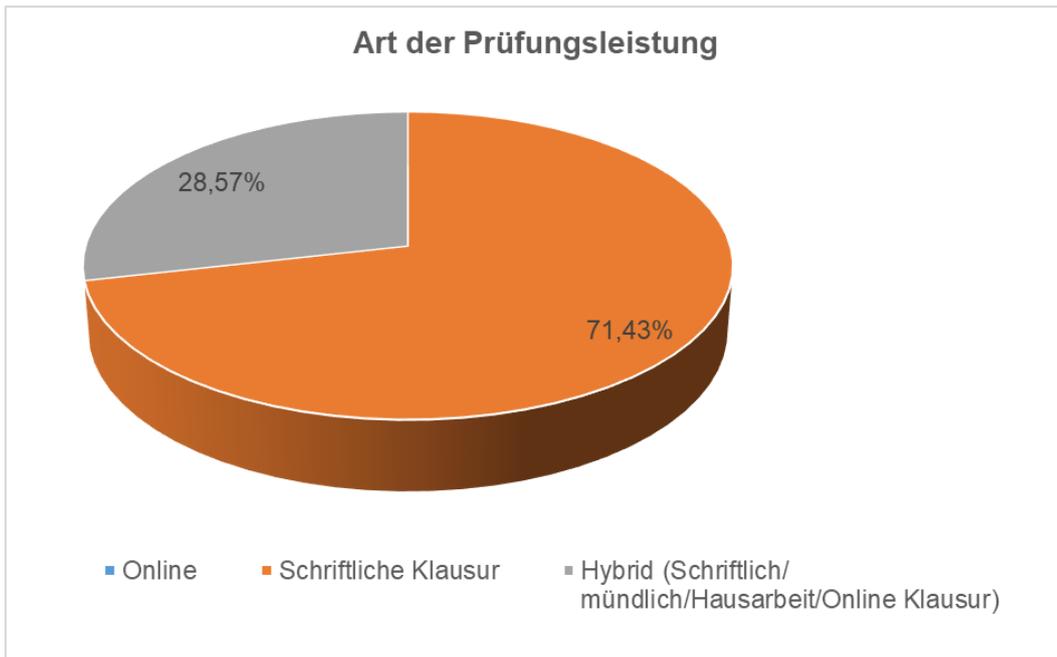


Abbildung G.2: Art der Prüfungsleistung bzgl. des Moduls ME

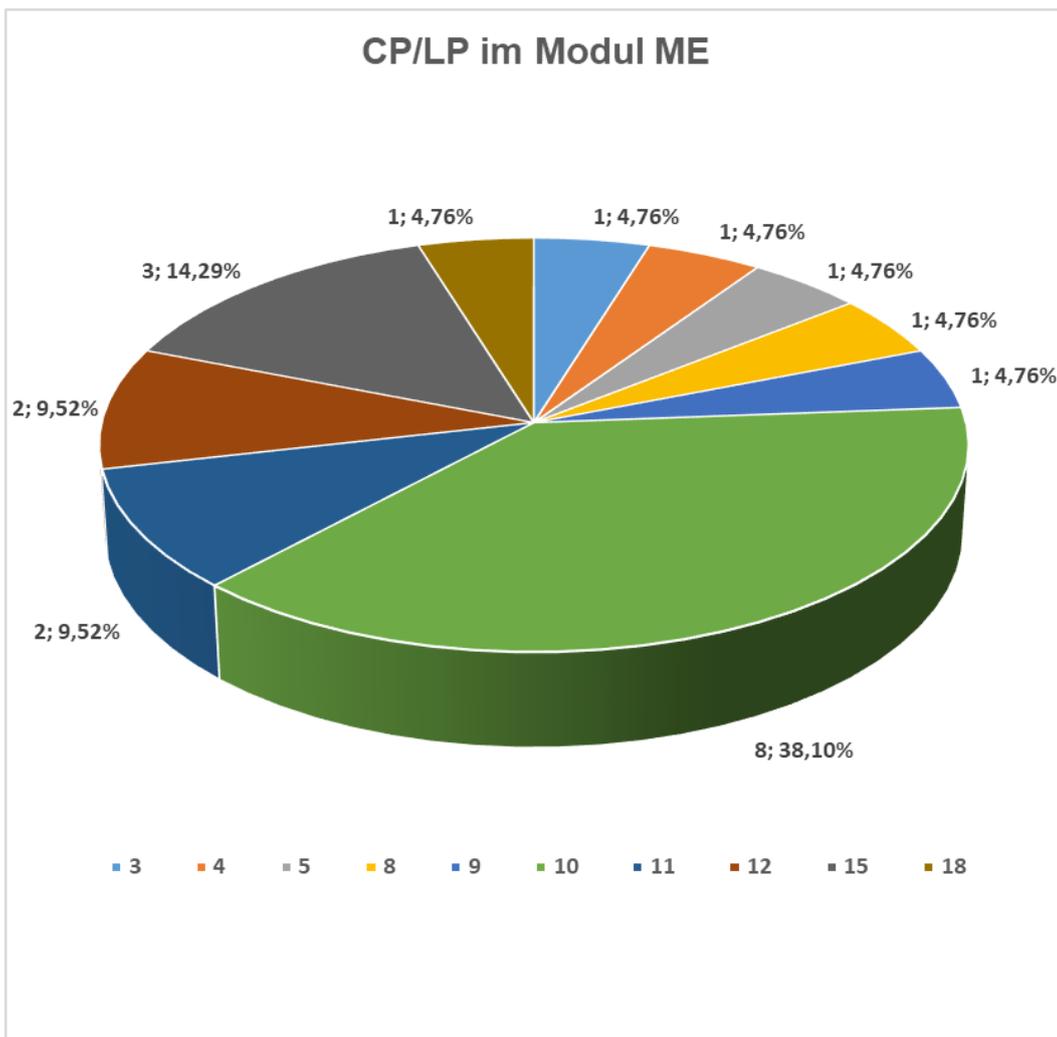


Abbildung G.3: Verteilung der CP/LP für das Modul Maschinenelemente in NRW

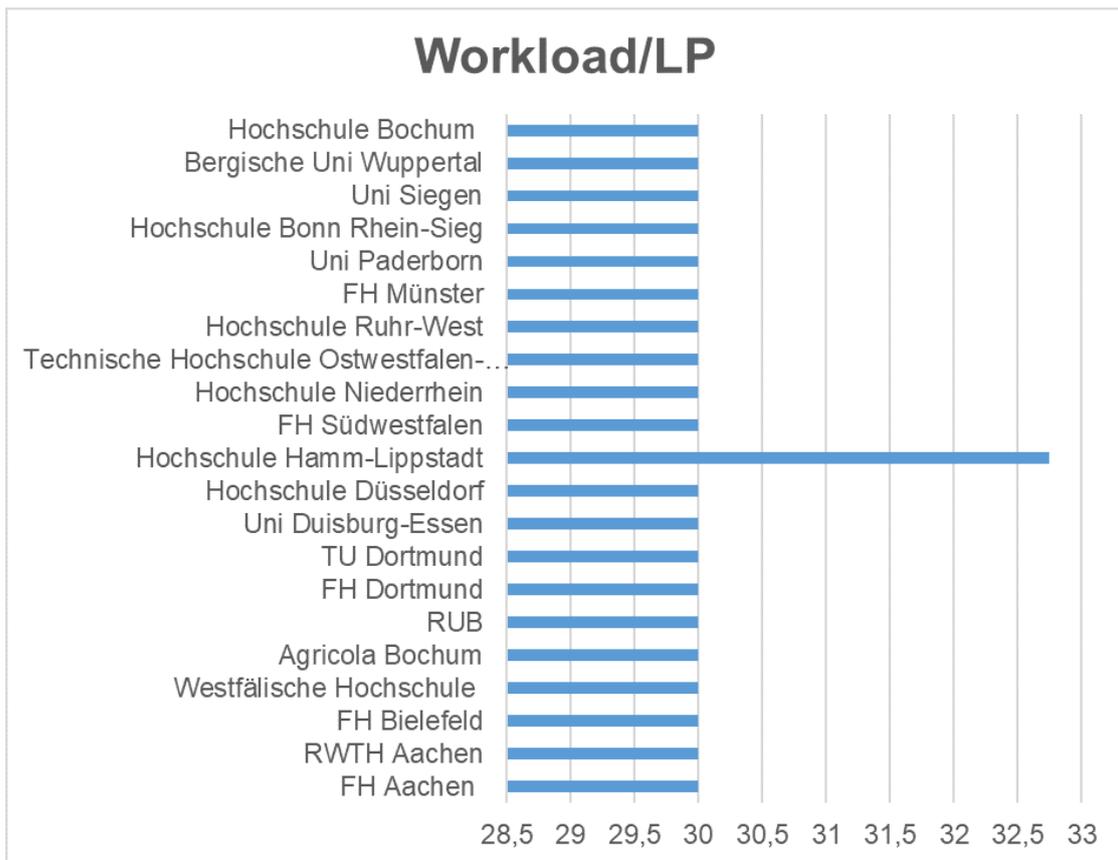


Abbildung G.4: Workload pro Leistungspunkt bzgl. des Moduls ME in NRW

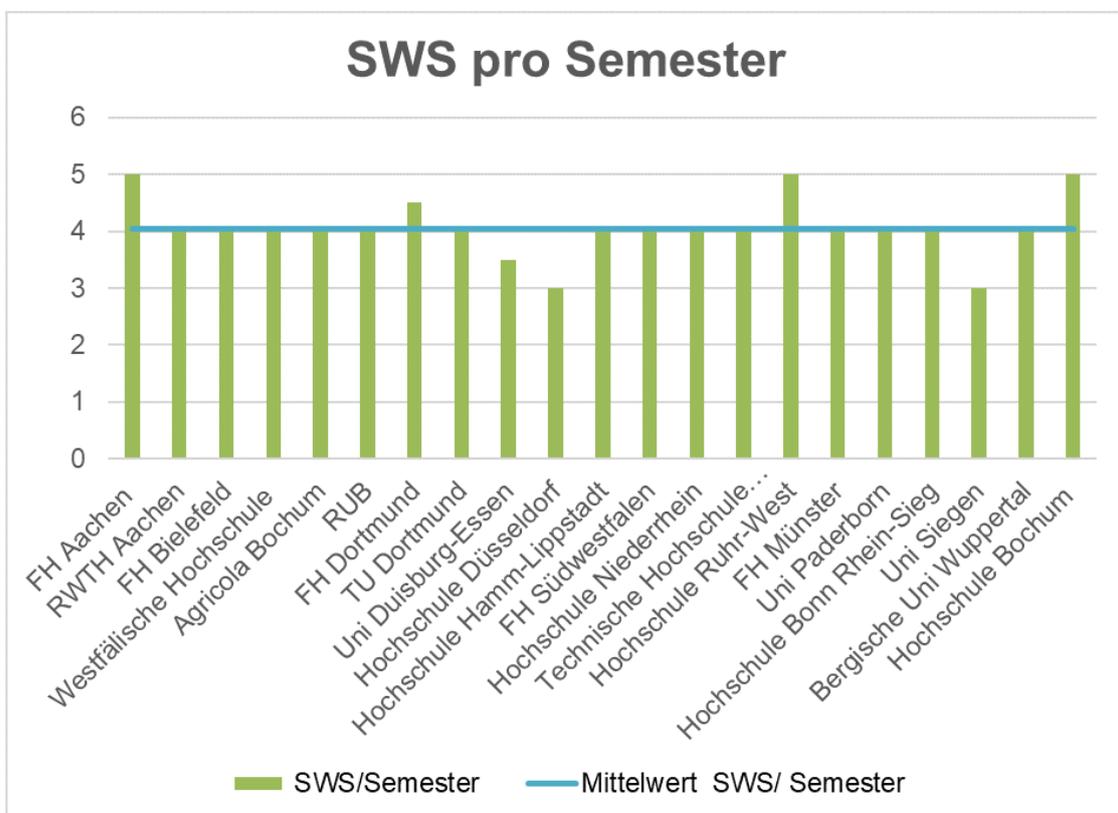


Abbildung G.5: Verteilung der SWS pro Semester in NRW in Bezug auf das Modul ME

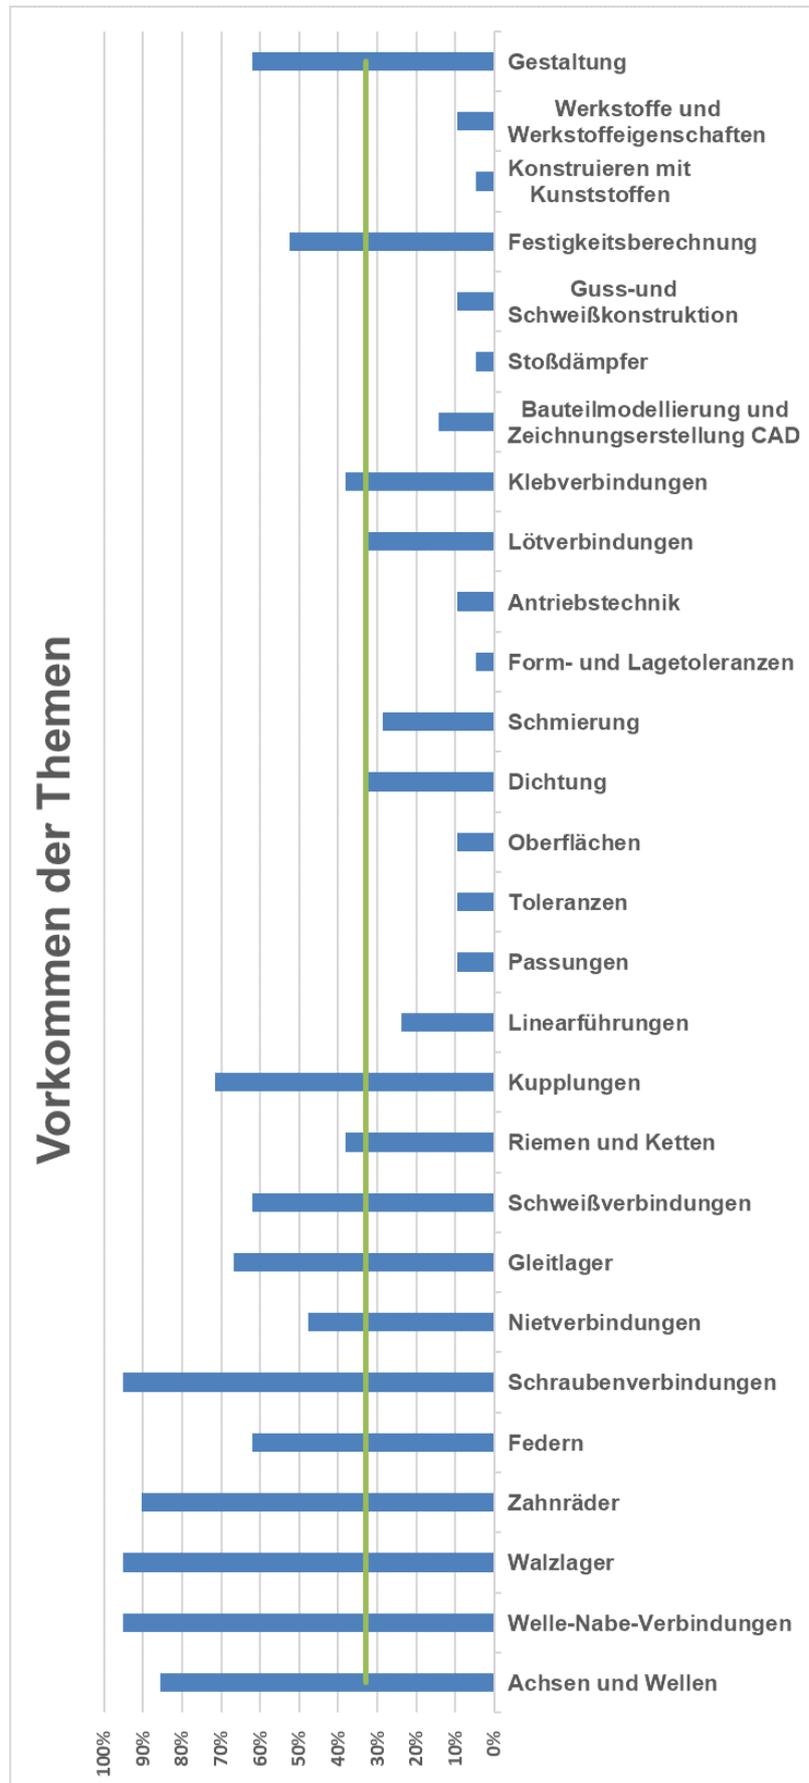


Abbildung G.6: Vorkommen der Themen im Fach Maschinenelemente an NRW Hochschulen

# H ChatGPT zu Gestaltabweichungen in der geometrischen Produktspezifikation (GPS)

Welche Gestaltabweichungen gibt es innerhalb der geometrischen Produktspezifikation?

*ChatGPT:*

*„In der geometrischen Produktspezifikation (GPS) gibt es verschiedene Gestaltabweichungen, die dazu dienen, die Geometrie und Toleranzen von Bauteilen zu beschreiben. Hier sind einige der wichtigsten Gestaltabweichungen in der GPS:*

*Geradheit (Straightness): Beschreibt die Abweichung einer Linie oder Achse von ihrer idealen geraden Form.*

*Rundheit (Roundness): Beschreibt die Abweichung einer kreisförmigen Fläche oder eines zylindrischen Elements von einer idealen Rundform.*

*Ebenheit (Flatness): Beschreibt die Abweichung einer Fläche von ihrer idealen ebenen Form.*

*Parallelität (Parallelism): Beschreibt die Abweichung zweier paralleler Flächen oder Achsen voneinander.*

*Senkrechtigkeit (Perpendicularity): Beschreibt die Abweichung des Winkels zwischen zwei Flächen oder Achsen, die senkrecht zueinander stehen sollten.*

*Zentrierung (Concentricity): Beschreibt die Abweichung der Achsen von zwei kreisförmigen Elementen, die in derselben Achse zentriert sein sollten.*

*Zylindrizität (Cylindricity): Beschreibt die Abweichung einer zylindrischen Fläche oder eines zylindrischen Elements von der idealen zylindrischen Form.*

*Profilabweichungen (Profile of a Line/Profile of a Surface): Beschreiben die Abweichung einer Linie oder einer Fläche von ihrer idealen geometrischen Form.*

*Diese Gestaltabweichungen dienen dazu, die erlaubten Toleranzen und die funktionale Geometrie von Bauteilen zu definieren. Sie ermöglichen es, die Anforderungen an die geometrische Form und Passung von Bauteilen präzise festzulegen und somit die Qualität und Austauschbarkeit von Produkten sicherzustellen.“ [OPE23a]*