

Gestaltung tutorieller Assistenzsysteme für Anwendungen des maschinellen Lernens in der Produktion

Vom Fachbereich Maschinenbau

an der Technischen Universität Darmstadt

zur

Erlangung des Grades eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte

D i s s e r t a t i o n

vorgelegt von

Jannik Rosemeyer, M.Sc.

Erstgutachter: Prof. Dr.-Ing. Joachim Metternich

Zweitgutachter: Prof. Dr.-Ing. habil. Fazel Ansari

Darmstadt 2025

Rosemeyer, Jannik: Gestaltung tutorieller Assistenzsysteme für Anwendungen des maschinellen Lernens in der Produktion

Darmstadt, Technische Universität Darmstadt

Jahr der Veröffentlichung der Dissertation auf TUpriints: 2025

Tag der mündlichen Prüfung: 16. Juli 2025

Zu veröffentlichen unter CC BY-SA 4.0 International

<https://creativecommons.org/licences/>

Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit, abgesehen von den in ihr ausdrücklich genannten Hilfen, selbständig verfasst habe.

16. Juli 2025, Jannik Rosemeyer

Datum, Unterschrift

Vorwort des Herausgebers

Mithilfe Anwendungen des maschinellen Lernens (ML) lassen sich Daten effizient nutzen, um in der Produktion Abweichungen zu erkennen, zu analysieren und gegebenenfalls proaktiv zu vermeiden. Doch um ML-Anwendungen gewinnbringend einzusetzen, braucht es nicht nur Wissen über deren Funktionsweise, sondern vor allem Handlungsfähigkeit in der Projektierung und der Nutzung. Es zeigt sich aber, dass viele produzierende Unternehmen nicht über die nötige Kompetenz verfügen, um ML erfolgreich zur Anwendung zu bringen. Klassische externe Weiterbildungen eignen sich nur bedingt zum Schließen dieser Kompetenzlücke, da Mitarbeiter das Erlernte häufig nicht auf die spezifischen Aufgabenstellungen ihrer eigenen Unternehmen übertragen können.

An diesem Punkt setzt die vorliegende Dissertation an. Sie erarbeitet einen Ansatz zum arbeitsintegrierten Erlernen von ML, welcher Mitarbeitern einen leichteren Transfer von der Theorie zur Praxis bietet. Zur praktischen Realisierung des Lernens am Arbeitsplatz wird ein Vorgehen zur Gestaltung tutorieller Assistenzsysteme erarbeitet. Den Kernbestandteil der Arbeit stellt ein Gestaltungsmodell dar, mit dessen Hilfe ein geeignetes tutorielles Assistenzsystem konzeptioniert werden kann. Anhand einer Operationalisierungsmethode lassen sich die Komponenten des Modells anschließend in eine Software überführen.

Die Evaluation der so entstehenden Assistenzsysteme zeigt, dass deren kompetenzbildende Wirkung dem klassischen arbeitsfernen Lernen mindestens ebenbürtig ist und so auf zusätzliche Schulungen abseits des Arbeitsplatzes verzichtet werden kann. Darüber hinaus zeigt sich, dass entwickelte Assistenzsysteme in der industriellen Praxis einsetzbar sind und dort einen Mehrwert generieren. Die Dissertation leistet damit einen wichtigen Beitrag, um die Schwelle zur produktiven Anwendung von ML in der Produktion weiter abzusenken.

Darmstadt, im Juli 2025

Prof. Dr.-Ing. Joachim Metternich

Vorwort des Autors

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen (PTW) der TU Darmstadt. An dieser Stelle möchte ich mich bei allen Personen, die zum Gelingen der vorliegenden Arbeit beigetragen haben, bedanken.

Mein Dank gilt zunächst meinem Doktorvater Prof. Dr.-Ing. Joachim Metternich für die wissenschaftliche Betreuung sowie die vielen Diskussionen und inhaltlichen Anregungen. Prof. Dr.-Ing. habil. Fazel Ansari danke ich darüber hinaus für die Übernahme des Korreferats sowie die kritischen Rückfragen und Verbesserungsvorschläge zur Ausarbeitung.

Ganz herzlich danke ich dem Team der Forschungsgruppe CiP für den großartigen Zusammenhalt sowie die konstruktiven und inhaltlichen Diskussionen. Hier möchte ich vor allem meine (ehemaligen) Bürokolleginnen und -kollegen des Forschungsschwerpunkts „Lernfabriken und Kompetenzentwicklung für die Produktion“ nennen und insbesondere Dr.-Ing. Antonio Kreß, Dr.-Ing. Thomas Riemann, Jonas Barth und Michael Geis sowie Dr.-Ing. Astrid Weyand meinen Dank aussprechen. Ihr habt immer wieder mit neuen Impulsen, Ratschlägen und Motivation zum Gelingen meines Forschungsvorhabens beigetragen. Mein Dank gilt auch Dr.-Ing. Sebastian Bardy für die inhaltlichen Diskussionen und Anregungen im Zuge der Nutzung für das arbeitsintegrierte Lernen. Sophie Sandner, Maximilian Steinmeyer und Enno Lang danke ich darüber hinaus für das Feedback in unseren Dissertationsaustauschen. Letztlich möchte ich mich bei Dr.-Ing. Nicholas Frick und Dr.-Ing. Nicolas Jourdan für die Übernahme der Korrektur bedanken.

Eine besondere Rolle nehmen meine ehemaligen Studentinnen und Studenten ein, die durch ihre Arbeit wertvolle Elemente dieser Dissertation erschlossen haben. Hier möchte ich vor allem Laurenz Beck, Yilin Tian und Jana Haselberger sowie das Team des Bachelorpraktikums Informatik nennen, die mich sehr unterstützt haben.

Mein herzlichster Dank gilt meinen Eltern und meiner Schwester, die mich immer bestärkt und auch über meine Promotion hinaus unterstützt haben. Aus tiefstem Herzen danke ich dabei Dir, Lara, für deine Unterstützung, Liebe und Aushalten während der Erstellung meiner Dissertation. Letztlich danke ich meinem himmlischen Vater für seine Gnade. Ohne euch wäre ich heute nicht da, wo ich jetzt stehe. Ihr habt mir Rückhalt, Liebe und eine Familie geschenkt.

Darmstadt, im Juli 2025

Jannik Rosemeyer

INHALTSVERZEICHNIS

Inhaltsverzeichnis	I
Abbildungsverzeichnis.....	V
Tabellenverzeichnis	VII
Abkürzungen und Formelzeichen	VIII
1 Einleitung	1
1.1 Problemstellung und Motivation	1
1.2 Zielstellung der Arbeit	3
1.3 Aufbau der Arbeit	3
2 Stand der Wissenschaft und Technik	7
2.1 Grundlagen des maschinellen Lernens	7
2.1.1 Definition und Begriffsabgrenzung.....	7
2.1.2 ML-Anwendungen in der Produktion	10
2.1.3 Rollen für die Implementierung von ML-Anwendungen.....	13
2.1.4 Prozessmodelle zur Unterstützung des Projektmanagements	14
2.1.5 Zwischenfazit zu den Grundlagen des maschinellen Lernens	16
2.2 Grundlagen betrieblicher Weiterbildung	17
2.2.1 Definition und Begriffsabgrenzung.....	17
2.2.2 Grundlagen des betrieblichen Lernens	21
2.2.3 Schulungsgestaltung für die betriebliche Weiterbildung	24
2.2.4 Kompetenzen für ML-Anwendungen in der Produktion	25
2.2.5 Weiterbildungsangebote zu ML-Anwendungen in der Produktion	28
2.2.6 Zwischenfazit zu den Grundlagen betrieblicher Weiterbildung	32
2.3 Digitale Assistenzsysteme für die Produktion.....	33
2.3.1 Definition und Begriffsabgrenzung.....	33
2.3.2 Tutorialsysteme zur Lernunterstützung	36
2.3.3 Entwicklung digitaler Assistenzsysteme	37
2.3.4 Tutorielle Assistenzsysteme zur Unterstützung von ML-Projekten	42
2.3.5 Zwischenfazit zu den Grundlagen digitaler Assistenzsysteme	45
2.4 Fazit zum Stand der Technik und Identifikation der Forschungslücke	45
3 Zielsetzung und Forschungskonzeption	47

3.1	Konkretisierung der Zielsetzung -----	47
3.2	Forschungskonzeption und gewählte Methoden -----	48
3.3	Eingrenzung des Untersuchungsbereichs -----	51
4	Gestaltungsmodell für tutorielle Assistenzsysteme -----	53
4.1	Modelltheorie -----	53
4.2	Methodisches Vorgehen bei der Entwicklung -----	54
4.3	Ermittlung inhaltlicher Anforderungen an das Gestaltungsmodell -----	55
4.3.1	Wissenschaftliche Fundierung der Anforderungen -----	55
4.3.2	Detaillierte Erläuterung der inhaltlichen Anforderungen -----	56
4.4	Subsysteme des Gestaltungsmodells -----	59
4.4.1	Schematischer Aufbau des Gestaltungsmodells -----	59
4.4.2	Subsystem Voraussetzungen -----	60
4.4.3	Subsystem Design -----	61
4.4.4	Subsystem Didaktik -----	61
4.4.5	Subsystem Befähiger -----	61
4.4.6	Synthese zu einem Gestaltungsmodell -----	62
4.5	Detaillierung der Gestaltungsmodellkomponenten -----	62
4.5.1	Subsystem Voraussetzungen -----	62
4.5.2	Subsystem Didaktik -----	65
4.5.3	Subsystem Design -----	67
4.6	Zwischenfazit zum Gestaltungsmodell -----	78
5	Konzeptionierung der Operationalisierungsmethode -----	79
5.1	Methodentheorie -----	79
5.2	Ordnungsrahmen und Phasen der Methode -----	80
5.3	Detailvorstellung der Phasen -----	82
5.3.1	Planen des Gestaltungsprozesses -----	82
5.3.2	Festlegen der Nutzungsanforderungen -----	83
5.3.3	Erarbeiten von Gestaltungslösungen -----	85
5.3.4	Evaluiieren der Gestaltung -----	97
5.4	Zwischenfazit und Diskussion zur Methodenentwicklung -----	98
6	Anwendung und Evaluation von Gestaltungsmodell und Methode -----	101
6.1	Operationalisierung in eine Softwarearchitektur -----	101

6.1.1 Planen des Gestaltungsprozesses-----	101
6.1.2 Festlegen der Nutzungsanforderungen -----	101
6.1.3 Erarbeiten von Gestaltungslösungen -----	103
6.1.4 Evaluieren der Gestaltung-----	111
6.1.5 Zwischenfazit zur Entwicklung des Tutorialsystems -----	112
6.2 Anwendung in der Praxis-----	113
6.2.1 Methodisches Vorgehen zur Anwendung und Evaluation -----	113
6.2.2 Vorbereitung der Anwendung -----	114
6.2.3 Durchführung der Anwendung -----	118
6.3 Auswertung von Anwendungs- und Erfolgsevaluation -----	122
6.3.1 Evaluation der inhaltlichen und formalen Anforderungen -----	122
6.3.2 Evaluation der Lernziele -----	124
6.4 Kritische Diskussion der Ergebnisse -----	129
6.5 Zwischenfazit zur Anwendung und Evaluation -----	132
7 Zusammenfassung und Ausblick -----	133
7.1 Zusammenfassung der Arbeit-----	133
7.2 Ausblick auf zukünftige Forschungsarbeiten-----	135
8 Literaturverzeichnis -----	137
Anhang-----	171
A1: Vergleich der vorgestellten Prozessmodelle-----	171
A2: Analyseverfahren der Internetrecherche-----	173
A3: Durchführung der Kano-Analyse-----	174
A3.1: Theorie der Kano-Analyse-----	174
A3.2: Fragenkatalog auf Basis des Kano-Modells-----	175
A4: Operationalisierungsmethode in BPMN-Darstellung -----	178
A5: Kriterien für die Wahl einer Technologie-----	179
A6: Übersicht über Busprotokolle und Kommunikationsprotokolle -----	180
A6.1: Industrierelevante Busprotokolle -----	180
A6.2: Industrierelevante Kommunikationsprotokolle-----	181
A7: Vergleich der Merkmalsextraktions- und selektionsmethoden -----	182
A8: Vergleich von Datenbanksystemen und Dateiformaten-----	183
A8.1: Vergleich verschiedener Datenbanksysteme -----	183

A8.2: Bewertung der angeführten Dateiformate	184
A9: Vollständige Kompetenztabelle	185
A10: Verhaltensanker für die Beobachtung	188
A11: Fragen des Leistungstests	190
A12: Betreute Abschlussarbeiten	191
A13: Publikationsübersicht	192

ABBILDUNGSVERZEICHNIS

Abbildung 1: Aufbau der Forschungsarbeit	4
Abbildung 2: Visualisierung von Supervised und Unsupervised Learning	9
Abbildung 3: Klassifikation von Prognoseansätzen	12
Abbildung 4: Einordnung des Citizen Data Scientists	14
Abbildung 5: Wissenstreppe nach North	18
Abbildung 6: Zusammenhang von Wissen, Qualifikation und Kompetenz	19
Abbildung 7: Zusammenhang von Kompetenz und Performanz	20
Abbildung 8: Formen des arbeitsbasierten Lernens	23
Abbildung 9: Mögliche Abfolgen von Aktivitäten	25
Abbildung 10: Vorgehen zum sozialen Lernen am Arbeitsplatz	25
Abbildung 11: Verteilung der untersuchten Weiterbildungen nach Arbeitsplatznähe ..	32
Abbildung 12: Charakteristika digitaler Assistenzsysteme	34
Abbildung 13: Architektur digitaler Assistenzsysteme	38
Abbildung 14: Entwicklung menschenzentrierter Systeme	39
Abbildung 15: Handlungsfelder bei der Entwicklung digitaler Assistenzsysteme	41
Abbildung 16: Methoden im Handlungsfeld Didaktik	41
Abbildung 17: Untersuchungsrahmen der systematischen Literaturrecherche	43
Abbildung 18: Vorgehen zur Entwicklung des Gestaltungsmodells	55
Abbildung 19: Schematischer Aufbau des Gestaltungsmodells	60
Abbildung 20: Gestaltungsmodell für tutorielle Assistenzsysteme	62
Abbildung 21: Potenzielle ML-Modelle für ein TAS	64
Abbildung 22: Mobile und stationäre Umsetzungsmöglichkeiten für ein TAS	65
Abbildung 23: Zusammenfassung möglicher Expositionsmaterialien	66
Abbildung 24: Kriterien lernförderlicher Arbeitsgestaltung	66
Abbildung 25: Verallgemeinerter Ablauf der angeführten Prozessmodellphasen	68
Abbildung 26: Kriterien einfacher Sprache	71
Abbildung 27: Datenvorbereitung und Modellierung bei einer ML-Anwendung	71
Abbildung 28: Grundsätze der Informationsdarstellung	73
Abbildung 29: Datenbanken in der industriellen Praxis	77
Abbildung 30: Operationalisierungsmethode mit Gestaltungskomponenten	82
Abbildung 31: Vorgehen zur Konzeptionierung der Netzwerkinfrastruktur	87
Abbildung 32: Mögliche Produktionsdaten	89
Abbildung 33: Vorgehen zur Datenvorbereitung	91
Abbildung 34: Mögliche statistische Merkmale für Zeitreihen	92
Abbildung 35: Reihenfolge bei der Umsetzung von Merkmalen	96
Abbildung 36: Schematische Darstellung des Assistenzsystems	104
Abbildung 37: Vorgehen im Technischen Verständnis	105
Abbildung 38: Datenvorbereitung im TAS	106
Abbildung 39: Vorgehen in der Modellierung	107

Abbildung 40: Maßnahmen zur Erreichung von Lernförderlichkeit -----	108
Abbildung 41: Didaktischer Aufbau des TAS-----	111
Abbildung 42: Vorgehen zur Unterstützungsevaluation -----	111
Abbildung 43: Visualisierung des operationalisierten TAS -----	112
Abbildung 44: Methodisches Vorgehen bei der Anwendung -----	113
Abbildung 45: Vorgehen bei der Handlungsaufgabe-----	115
Abbildung 46: Verteilung der Studenten nach Studiengang -----	118
Abbildung 47: Vereinfachter Wertstrom der CiP -----	119
Abbildung 48: Zwischenstände aus der Anwendung in der betrieblichen Praxis -----	122
Abbildung 49: Veränderung der Handlungselemente -----	125
Abbildung 50: Veränderung der Wissens Elemente -----	127
Abbildung 51: Operationalisierungsmethode gemäß BPMN -----	178

TABELLENVERZEICHNIS

Tabelle 1: Anwendungsfälle für ML-Anwendungen in der Produktion -----	10
Tabelle 2: Wege der Kompetenzentwicklung -----	21
Tabelle 3: Übersicht über ermittelte Kompetenzen für die Zielgruppe -----	28
Tabelle 4: Forschungsprozess der vorliegenden Arbeit -----	48
Tabelle 5: Formale Anforderungen für das Gestaltungsmodell -----	54
Tabelle 6: Zusammenfassung der inhaltlichen Anforderungen -----	59
Tabelle 7: Auswahl relevanter Kompetenzen anhand des Zielbilds -----	63
Tabelle 8: Ergebnisse aus der Kano-Analyse -----	69
Tabelle 9: Beispiele für präzise und unspezifische Fehlermeldungen -----	74
Tabelle 10: Formale Anforderungen an die Methode -----	80
Tabelle 11: Anwendungsfälle und respektive ML-Modelle -----	84
Tabelle 12: Exemplarische Kompetenztabelle -----	85
Tabelle 13: Übersicht über verschiedene mögliche Diagramme -----	90
Tabelle 14: Auszug aus der Kompetenztabelle -----	102
Tabelle 15: Verwendete Datenbankansätze im TAS -----	108
Tabelle 16: Bewertung inhaltlicher und formaler Anforderungen -----	123
Tabelle 17: Vergleich der Handlungselemente von Experimental- und Kontrollgruppe -----	126
Tabelle 18: Vergleich der Wissens Elemente von Experimental- und Kontrollgruppe	127
Tabelle 19: Veränderung der Teilkompetenzen in der industriellen Anwendung -----	128
Tabelle 20: Cohens gewichtetes Kappa je Handlungselement -----	129
Tabelle 21: Vergleich der vorgestellten Prozessmodelle -----	171
Tabelle 22: Verteilung der Veranstaltungen nach Anbieter -----	173
Tabelle 23: Funktionale und dysfunktionale Fragen in der Kano-Analyse -----	175
Tabelle 24: Kriterien für die Auswahl einer geeigneten Technologie -----	179
Tabelle 25: Vergleich von Busprotokollen -----	180
Tabelle 26: Übersicht über verschiedene Netzwerkprotokolle -----	181
Tabelle 27: Vergleich der vorgestellten Extraktions- und Selektionsmethoden -----	182
Tabelle 28: Vergleich von Datenbanksystemen -----	183
Tabelle 29: Vergleich von JSON, XML und CSV -----	184
Tabelle 30: Vollständige Kompetenztabelle -----	185
Tabelle 31: Verhaltensanker in der Beobachtung -----	188
Tabelle 32: Übersicht über betreute Abschlussarbeiten -----	191
Tabelle 33: Publikationen mit Vorarbeiten zu dieser Dissertation -----	192

ABKÜRZUNGEN UND FORMELZEICHEN

Abkürzung	Begriff
AiL	Arbeitsintegriertes Lernen
AIMM	Artificial Intelligence Management Model for the Manufacturing Industry
ANOVA	Analysis of Variances
AutoML	Automated Machine Learning
BMBF	Bundesministerium für Bildung und Forschung
BMWE	Bundesministerium für Wirtschaft und Energie
BPMN	Business Process Model and Notation
CDS	Citizen Data Scientist
CiP	Center für industrielle Produktivität
CoP	Community of Practice
CRISP-DM	Cross-Industry Standard Process for Data Mining
CRISP-ML(Q)	Cross-Industry Standard Process Model for the Development of Machine Learning Applications with Quality Assurance Methodology
CSV	Comma-separated values
DAS	Digitales Assistenzsystem
DASC-PM	Data Science Process Model
DIN	Deutsches Institut für Normung
DMME	Data Mining Methodology for Engineering Applications
DRM	Design Research Methodology
EG	Experimentalgruppe
EN	Europäische Norm
FAG	Formale Anforderung Gestaltungsmodell
FAM	Formale Anforderung Methode
FB	Forschungsbedarf
FTZ	Forschungsteilziel
GUI	Graphical User Interface
HCD	Human-centered Design
HCML	Human-centered Machine Learning
I4.0	Industrie 4.0
IA	Inhaltliche Anforderung
IHK	Industrie- und Handelskammer
IQA	Interquartilsabstand
ISO	International Organisation for Standardisation
IT	Informationstechnik

Abkürzung	Begriff
ITS	Intelligentes tutorielles System
JSON	JavaScript Object Notation
KAS	Kognitives Assistenzsystem
KDD	Knowledge Discovery in Databases
KDT-EA	Knowledge Discovery in Time series and Image Data for Engineering Applications
KG	Kontrollgruppe
KI	Künstliche Intelligenz
LASSO	Least Absolute Shrinkage and Selection Operators
LDA	Linear Discriminant Analysis
ML	Maschinelles Lernen
MOOC	Massive Open Online Courses
NoSQL	Not-only Structured Query Language
SEMMA	Sample, Explore, Modify, Model, Assess
SPS	Speicherprogrammierbare Steuerung
SQL	Structured Query Language
TAM	Technology Acceptance Model
TAS	Tutorielles Assistenzsystem
TK	Teilkompetenz
URL	Uniform Resource Locator
XML	Extensible Markup Language

Formelzeichen	Einheit	Größe
k_w	-	Cohens gewichtetes Kappa
p_G	-	Erreichte Punkte von Gruppe G
v_G	-	Verhaltensanker von Gruppe G

1 EINLEITUNG

1.1 Problemstellung und Motivation

Rund 15 Jahre nach ihrer Einführung durchdringen Industrie 4.0-Anwendungen (I4.0) zunehmend Fertigungsprozesse produzierender Unternehmen (Mockenhaupt 2021; Bitkom Research 2022). Dies bestätigt eine Studie des deutschen Bundesministeriums für Wirtschaft und Energie (BMWE). Demnach erachten 95% der befragten Unternehmen I4.0 als Chance und 91% sehen darin eine wesentliche Voraussetzung für den Erhalt der Wettbewerbsfähigkeit ihres Unternehmens (BMWE 2025). Bedingt durch die damit einhergehende Generierung großer Datenmengen entstehen für produzierende Unternehmen zahlreiche Möglichkeiten zur Produktivitätssteigerung und Verbesserung von Wertschöpfungsprozessen (Horvat und Som 2018; Bauer et al. 2018). Diese Einschätzung teilen auch die befragten Teilnehmer¹ einer aktuellen Studie. So versprechen sich 81% der Teilnehmer Produktivitätssteigerungen durch den Einsatz von Digitalisierung und 83% erhoffen sich eine schnellere Identifikation von Schwachstellen (Staufen AG 2024).

Trotz der technischen Fortschritte werden Mitarbeiter ein zentraler Teil der Produktion bleiben – lediglich mit veränderten Tätigkeiten (Rauch et al. 2020; Spöttl und Windelband 2019; Hulla et al. 2021). Hatten sie vormals insbesondere physische Aufgaben zu absolvieren, wird der Fokus zukünftig auf kognitiven und koordinativen liegen. Dies umfasst insbesondere die Prozessüberwachung und konsekutive Eingriffe sowie die Problemlösung bei Störungen. (Senderek et al. 2015; Rauch et al. 2020) Um die Potenziale von I4.0-Anwendungen gewinnbringend nutzen zu können, müssen Mitarbeiter zukünftig in der Lage sein, Informationen aus den generierten Daten zu extrahieren (Horvat und Som 2018). Da sie die anfallenden Datenmengen jedoch oftmals nicht mehr mit manuellen Methoden auswerten können, sind innovative Ansätze wie beispielsweise Algorithmen des maschinellen Lernens (ML) notwendig, um die aufgezeichneten Daten effektiv nutzen zu können (Bauer et al. 2018; Horvat und Som 2018; Kaiser et al. 2021; Peifer et al. 2022). Trotz der zugewiesenen Bedeutung von ML-Algorithmen zeigt sich eine Divergenz in der Verbreitung: Obwohl zunehmend Fortschritte durch ML-Anwendungen erzielt werden, nutzen nur wenige Unternehmen die Potenziale dieser (Metternich et al. 2021; Bauer et al. 2020). Diese Beobachtung zeigt sich für kleine und mittlere Unternehmen (KMU) umso mehr (Seifert et al. 2018; Metternich et al. 2021; Rammer 2022). Die Divergenz ist dabei insbesondere auf fehlende Kompetenzen im Umgang mit ML-Anwendungen zurückzuführen (Bauer et al. 2020; Hansen und Bøgh 2021; Metternich et al. 2021; André et al. 2021b). Selbst wenn sich Unternehmen mit der Implementierung von ML-Anwendungen befassen, erfolgt dies oftmals unstrukturiert und lässt damit zahlreiche

¹ Die in der vorliegenden Arbeit verwendeten Personenbezeichnungen beziehen sich gleichermaßen auf weibliche, männliche und diverse Personen. Auf eine Doppelnennung und gegenderte Bezeichnungen wird zugunsten einer besseren Lesbarkeit verzichtet.

Projekte scheitern (Ermakova et al. 2021; Sjödin et al. 2018). Dies führt zu einem Paradoxon: In Unternehmen entstehen in der Folge Bedenken gegenüber ML-Anwendungen, welche wiederum den notwendigen unternehmensinternen Kompetenzaufbau erschweren (Bauer et al. 2020). Zudem mangelt es vielen Mitarbeitern an Vertrauen, dass Datenanalysen ihre Entscheidungsfindung verbessern können. Ein Umstand, der ebenso auf mangelnde Kompetenzen zurückzuführen ist (Court et al. 2015).

Gemäß vorheriger Erläuterungen lässt sich im Kontext von I4.0- und ML-Anwendungen ein verändertes Qualifikationsprofil für Mitarbeiter produzierender Unternehmen feststellen (Botthof 2015; André et al. 2021a). Während Informationswissen über Produktionsprozesse in der Vergangenheit genügte, wird von ihnen nun insbesondere Handlungsfähigkeit durch Prozesseingriffe und Problemlösungen verlangt (Erpenbeck und Sauter 2013). Um dieser Herausforderung gerecht zu werden, ist es für Unternehmen unabdingbar, ihr Personal weiterzubilden (Gorecky et al. 2013). Die in Deutschland lange Zeit in Form von Frontalunterricht und durch externe Anbieter vorgenommene betriebliche Weiterbildung (Destatis 2022; Hahne 2003) genügt jedoch den aktuellen Ansprüchen nur unzureichend. So zeigen Untersuchungen von Kirkpatrick und Kirkpatrick (2010), dass nur circa 7–8% des frontal Gelehrten im Arbeitsumfeld wirklich verwendet wird. Der zu leistende Transfer gelernter Inhalte in den Unternehmensalltag wird hierbei von Mitarbeitern als schwierig empfunden und kann zu Überforderung führen (Mehler et al. 2021; Bergmann 1999). Zudem zeigen Erwachsene oftmals nur wenig Interesse und Aufnahmefähigkeit für frontalvermitteltes Wissen außerhalb des Arbeitsprozesses (Ng und Feldman 2012). Letztlich kann das notwendige Freistellen für Weiterbildungsveranstaltungen kurzfristig einen Wettbewerbsnachteil bewirken (Hacker 2015).

Es bedarf folglich innovativer Formen der Kompetenzentwicklung, welche die zuvor angeführten Defizite adressieren, damit Mitarbeiter mit den aktuellen Anforderungen von I4.0 im Allgemeinen und ML-Anwendungen im Speziellen Schritt halten können (Gorecky et al. 2013; Gabriel et al. 2024; André et al. 2021a). Insbesondere vor dem Hintergrund, dass sich die kontinuierliche Kompetenzentwicklung durch den digitalen Wandel in der Arbeitswelt beschleunigen muss (Richter et al. 2018), sind Unternehmen gefordert, Konzepte für die interne Qualifizierung zu erarbeiten (Böde et al. 2013).

An dieser Stelle greift das Lernen im Arbeitsprozess, sogenanntes arbeitsintegriertes Lernen, an. Es adressiert die zuvor aufgeführten Nachteile der klassischen Weiterbildung und erlaubt Unternehmen eine bessere Bewältigung technologischer Veränderungen (Dehnbostel 2018b). Folglich bietet es hohes Potenzial, den kontinuierlichen Bedarf nach neuen Kompetenzen zu adressieren (BMBF 2019b). Dies ist unter anderem darauf zurückzuführen, dass sich Fähigkeiten, wie beispielsweise die Problemlösung, besser im Arbeitsprozess entwickeln lassen und damit Schwierigkeiten beim Transfer von erworbenem Wissen in den Arbeitsprozess reduziert werden (Hartmann 2015; Mehler et al. 2021). Von der Forschung werden daher Instrumente gefordert, die das arbeitsintegrierte Lernen unterstützen (Richter et al. 2018). Einen Ansatz dazu stellt die Verknüpfung des arbeitsintegrierten Lernens mit technologiegestützten Lernformen dar (Senderek et al. 2015).

Zahlreiche Autoren postulieren, dass sogenannte kognitive Assistenzsysteme, und hierbei insbesondere tutorielle Assistenzsysteme, die Möglichkeit bieten, Mitarbeiter bei der Bewältigung ihrer kognitiven Tätigkeiten zu entlasten und zudem als Lernunterstützung zu fungieren (Mehler et al. 2021; Rauch et al. 2020; Romero et al. 2016; Apt et al. 2018a; Franken et al. 2022). Darüber hinaus wünschen sich Betriebe einer Studie aus dem Jahr 2023 zufolge keine klassische Weiterbildung im Themenkomplex ML, sondern fordern einen Ansatz zum praktischen Ausprobieren anhand eines konkreten Anwendungsfalls (Schliephake und Cordes 2023). Zum gegenwärtigen Zeitpunkt lässt sich jedoch beobachten, dass der Stand der Forschung den Bedarf an praktisch anwendbaren tutoriellen Assistenzsystemen nicht ausreichend abdeckt (Apt et al. 2018a). Vielmehr bedarf es zukünftig an Entwicklungen im Bereich der tutoriellen Assistenz. Von besonderer Bedeutung sind dabei Gestaltungsansätze, welche die systematische Entwicklung entsprechender Assistenzsysteme unterstützen.

1.2 Zielstellung der Arbeit

Im Kontext dieser Arbeit wird das postulierte Potenzial tutorieller Assistenzsysteme als Unterstützung für das arbeitsintegrierte Lernen auf den Anwendungsfall des maschinellen Lernens in der Produktion übertragen. Somit stellt die Arbeit eine Antwort auf die Forderungen von Hansen und Bøgh (2021) sowie Mazzei und Ramjattan (2022) dar. Den Autoren zufolge müssen ML-Anwendungen leichter zu implementieren und nutzen sein. Die Arbeit bietet darüber hinaus einen Beitrag zur Erreichung der strategischen Ziele der Europäischen Kommission und der deutschen Bundesregierung. Beide Institutionen avisieren eine zunehmende Verbreitung von ML-Anwendungen in produzierenden Unternehmen. Dazu stellen sie digitale und ML-bezogene Kompetenzen als unabdingbare Voraussetzungen dar, welche es im Kontext von Weiterbildungen aufzubauen gilt (BMBF 2019a; Europäische Kommission 2020).

Das Ziel der Arbeit lässt sich in der Summe wie folgt zusammenfassen:

Das **Ziel der Arbeit** besteht in der systematischen Gestaltung von tutoriellen Assistenzsystemen zur Ermöglichung von arbeitsintegriertem Lernen bei der Einführung von ML-Anwendungen in der Produktion.

Eine umfassende Beschreibung und Ausführung der Zielsetzung sowie der Forschungskonzeption erfolgen in Kapitel 3.

1.3 Aufbau der Arbeit

Der Aufbau dieser Arbeit orientiert sich an der Design Research Methodology (DRM) (Blessing und Chakrabarti 2009). Die insgesamt sieben Kapitel stellt Abbildung 1 schematisch dar. Die darauffolgende Beschreibung liefert einen kurzen Einblick in die einzelnen Kapitel.




Abbildung 1: Aufbau der Forschungsarbeit, eigene Darstellung in Anlehnung an Blesing und Chakrabarti (2009)

Kapitel 2 stellt den für die Arbeit relevanten Stand der Wissenschaft und Technik bereit. So wird eingangs notwendiges Hintergrundwissen für den Themenkomplex ML dargelegt (Abschnitt 2.1). Anschließend werden Grundlagen der betrieblichen Weiterbildung erläutert (Abschnitt 2.2), bevor eine Einführung in digitale Assistenzsysteme gegeben wird (Abschnitt 2.3). Den Abschluss bildet eine Zusammenfassung, in welcher zudem die Forschungslücke ausgeführt wird (Abschnitt 2.4).

Kapitel 3 baut auf der Zielstellung aus Abschnitt 1.2 auf und konkretisiert diese in Abschnitt 3.1 unter Berücksichtigung der Erkenntnisse aus Kapitel 2. In diesem Zusammenhang werden drei Teilziele zu dem übergeordneten Ziel eingeführt, welche das Vorgehen der weiteren Kapitel leiten. In Abschnitt 3.2 wird zudem die methodische Forschungskonzeption mit Hinblick auf die darauffolgenden Kapitel beleuchtet. Zur Präzisierung des Forschungsziels wird darüber hinaus erläutert, welche Entwicklungsschritte und Zielstellungen nicht Gegenstand der Untersuchung sind (Abschnitt 3.3).

In Kapitel 4 wird ein Gestaltungsmodell präsentiert, welches als konzeptionelle Grundlage zu entwickelnde Assistenzsysteme fungiert. Für ein tieferes Verständnis wird dazu zunächst ein Blick auf die Modelltheorie geworfen (Abschnitt 4.1) und im Anschluss das methodische Vorgehen bei der Entwicklung vorgestellt (Abschnitt 4.2). Relevante inhaltliche Anforderungen, welche in der Literatur beschrieben sind, werden in Abschnitt 4.3 zusammengetragen. Im Anschluss werden die einzelnen Subsysteme des

Gestaltungsmodells erläutert, welche daraufhin zum eigentlichen Gestaltungsmodell zusammengeführt werden (Abschnitt 4.4). Auf die einzelnen Komponenten innerhalb der Subsysteme wird anschließend vertiefend eingegangen (Abschnitt 4.5). Das Kapitel endet mit einer Zusammenfassung (Abschnitt 4.6).

Im darauffolgenden Kapitel 5 wird eine Operationalisierungsmethode zum Überführen des Gestaltungsmodells in eine Softwarearchitektur vorgestellt. Nach einer Einführung in die Methodentheorie (Abschnitt 5.1) wird die Operationalisierungsmethode weiter ausgeführt. Dazu wird zunächst der Ordnungsrahmen mit seinen Phasen erläutert (Abschnitt 5.2). Im Anschluss werden diese konkretisiert und Handlungsalternativen vorgestellt (Abschnitt 5.3). Das Kapitel schließt mit einem Zwischenfazit (Abschnitt 5.4).

Kapitel 6 beschreibt die Anwendung und Evaluation von Gestaltungsmodell und Operationalisierungsmethode. Auf Basis des Modells wird anhand der Methode zunächst eine Softwarearchitektur erarbeitet (Abschnitt 6.1). Diese wird daraufhin prototypisch umgesetzt und in zwei Anwendungsfällen erprobt (Abschnitt 6.2). Im Anschluss erfolgt eine Evaluation der erarbeiteten Lösungen (Abschnitt 6.3). Die erzielten Ergebnisse werden zudem einer kritischen Diskussion unterworfen (Abschnitt 6.4), bevor ein Zwischenfazit die wesentlichen Erkenntnisse aus Anwendung und Evaluation zusammenfasst (Abschnitt 6.5).

Kapitel 7 stellt das letzte Kapitel der Arbeit dar. Es erfolgt zunächst ein Rückblick auf die vorgenommenen Schritte und eine zusammenfassende Beantwortung aller aufgestellten Forschungsteilziele (Abschnitt 7.1). Ein Ausblick auf zukünftige Forschungsideen schließt die Arbeit ab (Abschnitt 7.2).

2 STAND DER WISSENSCHAFT UND TECHNIK

Die Gestaltung tutorieller Assistenzsysteme basiert auf unterschiedlichen Forschungsfeldern. Entsprechend wird im Folgenden eine Einführung in die Themenkomplexe maschinelles Lernen (Abschnitt 2.1), betriebliche Weiterbildung (Abschnitt 2.2) und digitale Assistenzsysteme (Abschnitt 2.3) gegeben. Abschließend werden Handlungsbedarfe und Forschungsdefizite aufgezeigt und ein zusammenfassendes Verständnis für das darauf aufbauende Forschungsvorhaben erarbeitet (Abschnitt 2.4).

2.1 Grundlagen des maschinellen Lernens

Um die relevanten Grundlagen des maschinellen Lernens aufzuzeigen, werden zunächst verschiedene Definitionen vorgestellt sowie notwendige Begriffe eingeführt (Abschnitt 2.1.1). Daraufhin werden Lösungen für die Produktion aufgezeigt (Abschnitt 2.1.2) sowie mögliche Rollen für die Implementierung eingeführt (Abschnitt 2.1.3). Im Anschluss wird ein Fokus auf Vorgehensmodelle für das strukturierte Bearbeiten von Projekten gelegt (Abschnitt 2.1.4). Ein Zwischenfazit fasst die Kernergebnisse des Abschnitts zusammen und zeigt Forschungsbedarfe auf (Abschnitt 2.1.5).

2.1.1 Definition und Begriffsabgrenzung

Bevor ein Verständnis für den Begriff des maschinellen Lernens geschaffen werden kann, ist es notwendig, dessen Oberbegriff, die *künstliche Intelligenz* (KI), näher zu beleuchten. Obgleich seine erstmalige Erwähnung bereits fast 70 Jahre zurückliegt (McCarthy et al. 2006), existiert für den Begriff KI bis heute keine allgemein anerkannte Definition. Konsens besteht darin, dass KI ein Aufgabenfeld der Informatik ist und darauf abzielt, menschliches Handeln und Denken zu replizieren (Bhosale et al. 2020; Rich 1987). Um diesen Mangel zusammenzufassen, stellen Russell und Norvig (2016) diverse Definitionen aus der Literatur in Abhängigkeit von ihrer Einordnung in Bezug auf menschliches Handeln beziehungsweise Denken und rationales Handeln beziehungsweise Denken gegenüber².

Die heutzutage gebräuchlichste Ausprägung im Zusammenhang mit KI-Anwendungen ist das *maschinelle Lernen*. Dieses verleiht Computern die Fähigkeit zu lernen ohne explizite Programmierung (in Anlehnung an Samuel (1959))³. Dabei beobachten entsprechende Anwendungen ihre Umwelt und lernen aus den Beobachtungen (Russell und Norvig 2016; Phan et al. 2022) sowie aus dem Sammeln von Erfahrungen (Mitchell 1997). Im Kontrast zu herkömmlichen Algorithmen läuft die Weiterentwicklung damit nicht auf Basis programmierter Abläufe ab, sondern durch die zielorientierte Verarbeitung von

² Für weiterführende Informationen sei auf die Autoren verwiesen.

³ Auf andere Ansätze wie Expertensysteme (Giarratano und Riley 2005) wird an dieser Stelle mangels Relevanz bei heutigen Anwendungen verzichtet.

Daten, bei der algorithmusspezifische Parameter während der Lernphase kontinuierlich angepasst werden (Mayr et al. 2019; Zhang et al. 2024). Um dies bewerkstelligen zu können bedarf es dreier Eigenschaften (Joshi 2020): Der *Eingabe von Daten*, einer *Fehlermetrik*, welche die Abweichung gegenüber einem idealen Zustand darstellt und einem *Feedbackmechanismus*, um das Programm basierend auf der Fehlermetrik zu leiten. Zusammenfassend wird der Begriff des ML für diese Arbeit in Anlehnung an Samuel (1959) und Phan et al. (2022) wie folgt definiert:

Definition Maschinelles Lernen:

Maschinelles Lernen bezeichnet die Fähigkeit von Algorithmen, durch die Beobachtung ihrer Umwelt zu lernen, ohne explizit programmiert worden zu sein.

Zur Strukturierung unterschiedlicher Arten von Lernaufgaben haben sich in Literatur und Praxis die drei Lernparadigmen Supervised, Unsupervised sowie Reinforcement Learning etabliert (Russell und Norvig 2016)⁴.

Beim *Supervised Learning* besteht der Datensatz aus einem Input $x_i, i = 1, \dots, n$ und einem ihnen zugeordneten Label oder Zielwert y_i . Das Ziel eines Algorithmus ist es daraufhin, einen Zusammenhang $y_i = f(x_i)$ zu finden. Mittels dieses Zusammenhangs können anschließend für zukünftige Beobachtungen Schätzungen des Zielwerts getroffen werden (siehe Abbildung 2). (Cady 2017; James et al. 2013) Zur Realisierung des Supervised Learnings lassen sich zwei Ansätze unterscheiden: Modelle mit einem quantitativen Zielwert y_i werden als Regressionsprobleme bezeichnet, während solche mit einem diskreten Label als Klassifikationsprobleme tituliert werden (James et al. 2013). Algorithmen für die Klassifikation sind unter anderem Entscheidungsbäume, Random Forests, lineare Klassifikatoren, Naive-Bayes-Klassifikatoren oder die k-Nächste-Nachbarn-Klassifikation. Eine Regression hingegen lässt sich gemeinhin beispielsweise mittels linearer oder polynomieller Regression realisieren. (Kreutzer 2023) Letztlich werden Algorithmen des Supervised Learnings unter anderem mittels folgender Leistungsmetriken bewertet:

- Klassifikation: Konfusionsmatrix (Traini et al. 2019) mit Accuracy, Precision und Recall sowie Receiver Operating Characteristics (Alpaydm 2022)
- Regression: Mittlerer quadratischer Wurzelfehler, Mittlerer absoluter Fehler, mittlerer quadrierter Fehler, unter anderem (Joshi 2020)

Beim *Unsupervised Learning* verfügt ein Algorithmus lediglich über Inputwerte $x_i, i = 1, \dots, n$, nicht aber über zugeordnete Zielwerte (siehe Abbildung 2). Vielmehr muss dieser Ähnlichkeiten, Muster oder Strukturen in den Daten eigenständig erkennen. Einem Anwender sind die identifizierten Muster im Vorfeld dabei nicht notwendigerweise bekannt.

⁴ Auf die vierte Form des Semi-Supervised Learning als Mischform von Supervised und Unsupervised Learning wird an dieser Stelle nicht vertiefend eingegangen.

Die durch den Algorithmus gewonnenen Erkenntnisse können somit auch außerhalb des Erwartbaren liegen. (Kreutzer 2023; Cady 2017; James et al. 2013) Typische Algorithmen für das Unsupervised Learning sind k-Means, Self Organizing Maps oder Autoencoder (Joshi 2020). Zur Bewertung werden Metriken wie euklidischer Abstand, Mahalanobis-Abstand, Minkowski-Abstand oder Manhattan-Abstand genutzt (Joshi 2020).




Abbildung 2: Visualisierung von Supervised und Unsupervised Learning, links: Supervised Learning, rechts: Unsupervised Learning eigene Darstellung in Anlehnung an Zhang et al. (2024)

Beim *Reinforcement Learning* lernt ein Algorithmus durch Rückmeldungen in Form von Belohnungen oder Bestrafungen auf vorgenommene Aktionen. Es ist sodann Aufgabe des Algorithmus zu entscheiden, welche Handlung welchen Einfluss auf eine erhaltene Rückmeldung hat. In der Folge muss der Algorithmus somit versuchen, die eigenen Handlungen derart zu verändern, dass die Rückmeldungen möglichst stark positiv ausfallen. (Russell und Norvig 2016) Eine ausführlichere Erläuterung der Funktionalität von Reinforcement Learning findet sich bei Sutton und Barto (2020).

Mit Hinblick auf die Vielzahl möglicher Algorithmen und der Tatsache, dass Algorithmen Parameter auf Basis von Mustern in den Eingabedaten justieren, können ML-Modelle derart komplex sein, dass selbst Programmierer sie nur schwer nachvollziehen können (Rudin und Radin 2019). Dieses Problem hat in der Forschung zu zwei Entwicklungsrichtungen geführt. Auf der organisatorischen Ebene stellt sich der Bedarf nach Einbezug des Menschen in die Entwicklung, betitelt als *menschenzentriertes maschinelles Lernen* (HCML⁵). HCML ist eine Menge von Methoden für den Aufbau, die Bewertung, den Einsatz und die Kritik von ML-Systemen, die ein Gleichgewicht zwischen technischen Innovationen sowie menschlichen und sozialen Belangen sicherstellen (Chancellor 2023). HCML-Anwendungen umfassen unter anderem die Entwicklung fairer und transparenter Algorithmen (Ribeiro et al. 2016), die Entscheidungsfindung durch den Menschen (Zhu et al. 2018), die Entwicklung von Mensch-ML-Kollaborationen (Amershi et al. 2019) sowie die Erforschung der sozialen Auswirkungen von ML (Chancellor 2023). Auf technischer Ebene erfolgt in den letzten Jahren die Erforschung von Methoden des *Automated Machine Learnings* (AutoML). AutoML beschreibt die automatisierte Erstellung mit einer Kombination verschiedener Techniken zu einer

⁵ Vom englischen Begriff Human-centered machine learning

einfach zu bedienenden End-to-End-ML-Pipeline (He et al. 2021). Für weitere Informationen zu AutoML sei auf die angegebene Literatur verwiesen.

2.1.2 ML-Anwendungen in der Produktion

Burggräf et al. (2021) unterteilen Produktionsprozesse in direkte Prozesse (Fertigung, Montage) und indirekte Prozesse (Produktionsplanung und Steuerung, Qualitätsmanagement, Instandhaltung, unter anderem). Anhand der aufgeführten Struktur wird im Folgenden eine Vertiefung von Anwendungsmöglichkeiten für ML-Anwendung in Produktionsumgebungen gegeben.

Im Zusammenhang direkter Prozesse können ML-Anwendungen in der Fertigung und Montage zum Einsatz kommen. Aggogeri et al. (2021) nutzen eine Literaturrecherche, um Anwendungen in Fertigungsprozessen zu ermitteln. Sie halten fest, dass ML-Modelle beispielsweise zur Ermittlung von Vibrationen, zur Rauheitsabschätzung und -vorhersage, zur prädiktiven Qualitätssicherung, zur Modellierung des Verhaltens von Werkzeugmaschinenkomponenten und Bauteilen sowie zur Maschinen- und Werkzeugzustandsüberwachung genutzt werden. Mypati et al. (2023) untersuchen Ansätze getrennt nach spezifischen Produktionsprozessen (Gießen, Zerspanung, Formen, Schweißen, unter anderem) und listen zahlreiche Lösungen auf. Auch sie kommen zu ähnlichen Anwendungsfällen. In Montageprozessen hingegen eignen sich ML-Anwendungen beispielsweise zur Prognose der Overall Equipment Effectiveness (Dobra und Jósvai 2023), zur Unterstützung der Mitarbeiter bei der Identifikation richtiger Komponenten (Andrianakos et al. 2019) und zur Prozessplanung (Zhang et al. 2022). Weitere produktionsbezogene Ansätze nutzen ML zur Vereinfachung der Ursachenfindung (Weichert et al. 2019), zur Interaktion von Mensch und Maschine (Mypati et al. 2023), zur Robotersteuerung (Mazzei und Ramjattan 2022), zum Hochlauf der Produktion (Doltsinis et al. 2018) oder zur Überwachung von Energieverbräuchen (Mhlanga 2023). In Summe ist ersichtlich, dass sich ML-Anwendungen dazu eignen, Aufgaben aus den indirekten Bereichen in die direkten Bereiche einzubinden, um somit die Funktionserfüllung indirekter Prozesse zu beschleunigen. Eine Zusammenfassung der Anwendungsfälle stellt Tabelle 1 bereit.

Tabelle 1: Anwendungsfälle für ML-Anwendungen in der Produktion

Anwendungsfall	Exemplarische Quelle
Prädiktive Qualitätssicherung	Aggogeri et al. (2021)
Zustandsüberwachung / Prädiktive Instandhaltung	Carvalho et al. (2019)
Prognose der Overall Equipment Effectiveness	Dobra und Jósvai (2023)
Identifikation richtiger Komponenten	Andrianakos et al. (2019)
Prozessplanung	Zhang et al. (2022)
Vereinfachung der Ursachenfindung	Weichert et al. (2019)
Interaktion von Mensch und Maschine	Mypati et al. (2023)
Robotersteuerung	Mazzei und Ramjattan (2022)

Anwendungsfall	Exemplarische Quelle
Hochlauf der Produktion	Doltsinis et al. (2018)
Überwachung von Energieverbräuchen	Mhlanga (2023)

Einer der häufigsten Anwendungsbereiche von ML-Lösungen in der Produktion ist die Instandhaltung (Mazzei und Ramjattan 2022). Immerhin ist die Wartung von Anlagen ein essenzieller Faktor für produzierende Unternehmen, der sich unmittelbar auf die Betriebszeit der Anlagen und ihrer Effizienz auswirkt (Carvalho et al. 2019). Für ML-Anwendungen eignen sich hierbei vor allem die *Zustandsorientierte Instandhaltung*⁶ und die *prädiktive Instandhaltung*. Beide Strategien dienen zur Beurteilung und Verminderung der Ausfallwahrscheinlichkeit eines Objekts (Deutsches Institut für Normung 2018b) und finden dementsprechend vor dem Ausfall einer Komponente statt. Mit Hilfe von ML-Algorithmen sowie Daten können im Kontext der beiden Strategien vor einem Komponentenausfall vertiefte Kenntnisse über den Maschinen- und Werkzeugzustand gewonnen werden und Instandhaltungsmaßnahmen genauer geplant werden (Schadler et al. 2019). Als Fundament dafür dient der sogenannte Abnutzungsvorrat (Deutsches Institut für Normung 2019b). Hierbei wird angenommen, dass sämtliche Komponenten über einen definierten Vorrat an Funktionserfüllungen verfügen, welcher sich im Zeitverlauf reduziert (Austerjost et al. 2016). Mit Einführung eines Mindestwerts, der Abnutzungsgrenze, kann dann das Ende der Funktionsfähigkeit von Komponenten markiert werden (Deutsches Institut für Normung 2019b; Wenzel 2013). Ein wesentlicher Aspekt von Zustandsüberwachungen ist die regelmäßige oder dauerhafte Überwachung von zu betrachtenden Komponenten. Der Aufwand dazu schwankt zwischen optischen Prüfungen, der Demontage einzelner Bauteile und der Zuhilfenahme von Sensorik (Leidinger 2017). Im Kontrast dazu hat die prädiktive Instandhaltung eine in die Zukunft gerichtete Prognose von Komponentenzuständen zum Ziel (Preusche 2018). Die Zeit bis zum Ausfall wird als Remaining Useful Lifetime bezeichnet und soll abgeschätzt werden.

Sutharssan et al. (2015) führen in ihrer Ausarbeitung verschiedene Ansätze zur Prognose von Maschinenzuständen an (siehe Abbildung 3). Den Autoren zufolge eignen sich hier insbesondere datenbasierte Ansätze. Datenbasierte Methoden, welche im Fokus dieser Arbeit stehen, können dabei wiederum mittels statistischer Methoden (parametrisch oder nicht-parametrisch) oder mit ML-Lösungen realisiert werden. Hierzu eignen sich vor allem Algorithmen des Supervised und Unsupervised Learnings (siehe Abschnitt 2.1.1).

⁶ Im Folgenden synonym als Zustandsüberwachung bezeichnet.




Abbildung 3: Klassifikation von Prognoseansätzen, eigene Abbildung in Anlehnung an Sutharssan et al. (2015)

In der betrieblichen Praxis zeigt sich wie in Kapitel 1 erläutert eine Divergenz zwischen Potenzial und Nutzung von ML-Anwendungen: während in der Forschung zahlreiche Lösungen entwickelt werden, welche einzelne sehr spezifische Probleme lösen (Elattar et al. 2016), haben Unternehmen Probleme in der tatsächlichen Umsetzung (Tiddens et al. 2015; van de Kerkhof et al. 2016). Dies kann darauf zurückgeführt werden, dass sich die Forschung vor allem auf technische Lösungen konzentriert und organisatorische Rahmenbedingungen nicht in angemessenem Umfang berücksichtigt (Tiddens et al. 2020). Generische und anwendungsfall-unabhängige Lösungen werden zudem kaum betrachtet (Lee et al. 2006). Tatsächlich aber bedürfen sowohl ML-Anwendungen maßgeblich organisatorischer Erfordernisse, wie beispielsweise der Kooperation diverser Personen mit unterschiedlichen Fähigkeiten und aus verschiedenen Abteilungen (Wagner und Hellingrath 2019).

Im Kontrast zu anderen Anwendungsbereichen weisen Produktionsumgebungen darüber hinaus Herausforderungen auf, die die Nutzung von ML-Anwendungen erschweren: Daten sind oftmals hoch-dimensional, zeitabhängig, nicht-stationär, unausgewogen und in verschiedenen Formaten vorhanden (Neunzig et al. 2023b). Bereits die Generierung relevanter Daten stellt zahlreiche Unternehmen vor Probleme (Wuest et al. 2016). Letztere Autoren führen weiter aus, dass sowohl Qualität als auch Quantität kritische Größen sind. Gleichermassen können unvollständige Datensätze, beispielsweise bedingt durch Sensorausfälle, die Aussagekraft von ML-Algorithmen beeinträchtigen (Pham und Afifi 2005; Wuest et al. 2016). Die Summe dieser Hindernisse stellt einen möglichen Erklärungsansatz dar, warum viele der von Metternich et al. (2021) befragten Unternehmen noch keine ML-Lösung umgesetzt haben. Auffällig ist allerdings, dass die Mehrheit der in der Studie Befragten eingesetzte Lösungen positiv bewertet und einen Gewinn daraus zieht. So lassen sich den Studienteilnehmern zufolge insbesondere die Arbeitsqualität und Prozesseffizienz erhöhen sowie Qualitätskosten reduzieren.

Wie dargestellt, setzen ML-Lösungen die Existenz von geeigneten Daten voraus. Für Anwendungen in der Produktion bestehen diese oftmals aus Zeitreihen. Allerdings sind beispielsweise Komponentenausfälle selten (Tian et al. 2024), wodurch der Prozess zur Generierung eines repräsentativen Datensatzes langwierig sein kann (Gay et al. 2022). Dabei verringern kleine Datensätze die Präzision datengestützter Prognosen, was zu einer

schlechteren Entscheidungsfindung zu führen vermag (zum Beispiel zu frühe Reparaturen oder nicht vermiedene Ausfälle) (Tiddens et al. 2015). Zur Behebung dieses Problems eignet sich der Ansatz der Datenerweiterung, durch welchen Datensätze vergrößert werden können (Gay et al. 2022). Auch die Erzeugung synthetischer Daten bietet eine Möglichkeit, die Datenbasis künstlich zu vergrößern und somit die Vorhersagekraft von Modellen zu erhöhen (Neunzig et al. 2023a).

2.1.3 Rollen für die Implementierung von ML-Anwendungen

In großen Unternehmen sind für die Implementierung von Innovationen in Produktionsumgebungen wie ML-Anwendungen dedizierte Fachabteilungen bestehend aus *Data Scientists* verantwortlich (Piorkowski et al. 2021). Anders sieht die Situation in KMU aus: diese besitzen oftmals keine entsprechenden Abteilungen (Dobler et al. 2022), was zur Folge hat, dass Innovationsprojekte als zusätzliche Arbeitslast angesehen werden (La Hoz Domínguez et al. 2020). Innovationsprojekte werden dabei oftmals durch *Prozessverantwortliche und Teamleiter im unteren Management* verantwortet, welche üblicherweise folgende Merkmale aufweisen: Sie haben ein hohes Maß an Expertise in ihrer jeweiligen Domäne, jedoch nur geringfügige Kenntnisse im Umgang mit Programmiersprachen (Dobler et al. 2022). Sie sind unternehmensintern stark vernetzt mit anderen ML-Stakeholdern, wie zum Beispiel der *Informationstechnik* (IT) oder dem über ihnen liegenden *Management*. Dadurch können sie den Aufwand (z.B. für die Anbindung von Datenquellen) und die Akzeptanz im Vergleich zu reinen Data Scientists besser einschätzen. (Merkelbach et al. 2022; Haman 2013) Zudem müssen sie für Verbesserungsprozesse *Mitarbeiter* qualifizieren, sodass diese an den Verbesserungsprozessen mitwirken können. Durch Coaching und zielorientierte Kommunikation binden sie diese in entsprechende Vorhaben ein und überprüfen kontinuierlich den Erfolg der Maßnahmen. (Haman 2013; Delbridge et al. 2000)

In einem zahlreich referenzierten Beitrag führt die Gartner Inc. das Konzept des sogenannten *Citizen Data Scientists* (CDS) ein und erläutert, dass CDS bestehende Expertiseprobleme zwischen dedizierten Data Scientists, Domänenexperten, dem Management sowie einer IT-Abteilung zur Implementierung von ML-Anwendungen lösen können (Gartner Inc. 2017). In Anlehnung an die Autoren wird für die Rolle des CDS im Kontext dieser Arbeit folgende Definition festgehalten:

Definition Citizen Data Scientist:

Eine Person, die ML-Modelle generiert, deren primäre Funktion jedoch nicht im Bereich der Datenanalysen liegt.

Insbesondere KMU könnten aufgrund des Mangels an Fachabteilungen von CDS in ihrer Belegschaft profitieren. CDS besitzen dabei umfangreiches Domänenwissen und lösen bestehende Probleme datenbasiert unter Verwendung von ML-Anwendungen (Li und Mocko 2020). Entsprechend können sie aufgenommene Daten mit Hinblick auf

Nutzbarkeit durch ML-Lösungen evaluieren und Ergebnisse von ML-Anwendungen gegen definierte Ziele bewerten. Diese können sodann für Prozessverbesserungen verwendet werden. (Mullarkey et al. 2019) Einfache Algorithmen können sie unter Verwendung von unterstützenden Werkzeugen erstellen, ohne allerdings umfangreiche Programmierfähigkeiten vorzunehmen (Alpar und Schulz 2022; Li und Mocko 2020). Letztlich besitzen sie die Expertise, ML-Projekte zu koordinieren und in diesem Zusammenhang interdisziplinär zwischen verschiedenen Stakeholdern zielorientiert zu kommunizieren (Mullarkey et al. 2019; Merkelbach et al. 2022). Von Relevanz ist dabei, Mitarbeiter zu CDS weiterzubilden (Gartner Inc. 2017). Abbildung 4 ordnet zum besseren Verständnis die Rolle des CDS im Unternehmen ein.




Abbildung 4: Einordnung des Citizen Data Scientists, eigene Darstellung in Anlehnung an Deuse et al. (2021)

2.1.4 Prozessmodelle zur Unterstützung des Projektmanagements

Eingangs wurde dargelegt, dass zahlreiche ML-Projekte aufgrund unstrukturierter Vorgehens nicht zu einem gewinnbringenden Ende geführt werden (siehe Abschnitt 1.1). Das Verfolgen eines systematischen Prozessmodells kann hierbei im Gegenzug Abhilfe schaffen. Prozessmodelle stellen eine Reihe an Tätigkeiten inklusive jeweiliger Eingangs- und Ausgangsgrößen dar, an dessen Ende das Lösen einer gegebenen Aufgabe steht (Pressman und Maxim 2015). Das finale Ziel eines Prozessmodells ist dabei, ein Projekt handhabbar, wiederholbar und messbar zu gestalten (Mariscal et al. 2010). Entsprechend wird in diesem Abschnitt ein Überblick über bestehende Prozessmodelle für ML-Projekte geliefert. Hierbei wird auch auf Modelle des Data Minings zurückgegriffen.

Der *Knowledge Discovery in Databases* (KDD) Prozess (Fayyad et al. 1996) will fachliche Zusammenhänge aus großen Datenbeständen extrahieren. Neben Algorithmen

werden dabei technische Beschreibungen sowie Herausforderungen im Kontext der Umsetzung beschrieben. Das wohl bekannteste Prozessmodell ist der *Cross-Industry Standard Process for Data Mining* (CRISP-DM) (Wirth und Hipp 2000). In sechs Schritten, beginnend mit der Einordnung des Problems auf Unternehmensebene bis hin zum Deployment, werden Entscheidungsträgern zu berücksichtigende Aspekte geboten, die bei der Durchführung von Data-Mining-Projekten zu beachten sind. Das *Sample, Explore, Modify, Model, Assess* (SEMMA) (Azevedo und Santos 2008) Modell beschreibt die strukturelle Basis der proprietären Software SAS Enterprise Miner. SEMMA umfasst eine Anzahl an sequenziellen Schritten, welche bei der Anwendung von Data Mining Projekten zu berücksichtigen sind. Dabei steht die Modellierung einer Data-Mining-Anwendung im Vordergrund. Aufbauend auf dem CRISP-DM wurden in der Folge weitere Modelle entwickelt, wie beispielsweise die *Data Mining Methodology for Engineering Applications* (DMME) (Huber et al. 2018; Wiemer et al. 2019). Die Autoren erweitern den CRISP-DM um drei weitere technische Schritte, die im Zusammenhang mit Anwendungen in der Produktion von Relevanz sind und dabei Aspekte wie Maschinen und Sensoren detaillierter betrachten. Studer et al. (2021) konzeptionieren das *Cross-Industry Standard Process Model for the Development of Machine Learning Applications with Quality Assurance Methodology* (CRISP-ML(Q)), welches sich vornehmlich an Softwareentwickler richtet und weniger an Domänenexperten. Darin wird ein dem CRISP-DM vergleichbarer Prozess aufgezeigt, welcher vertiefend ML-bezogene Aspekte thematisiert. Ergänzend erfolgt eine Überwachung und Instandhaltung des Modells hinsichtlich Modell- oder Parameteränderungen. Weiterhin an CRISP-DM angelehnt ist das *Data Science Process Model* (DASC-PM) (Schulz et al. 2020). Beginnend mit dem Projektauftrag bis hin zur tatsächlichen Nutzung werden fünf Bereiche definiert, welche sich in weiterführende Phasen unterteilen. Dabei wird auch die Netzwerkinfrastruktur, die Wissenschaftlichkeit sowie übergeordnet die Domäne näher in den Fokus genommen. Notwendige Personen und Rollen werden darüber hinaus erläutert. Ähnlich gestaltet ist das *Artificial Intelligence Management Model for the Manufacturing Industry* (AIMM) (Biegel et al. 2021), welches unterschiedliche Aufgaben für die strategische, taktische und operative Ebene definiert und ausgehend von einem Ist-Status einen Soll-Status gestaltet. Auch hier werden unterschiedliche Persona einbezogen sowie Drop-Out Gates definiert. Kubik et al. (2022) analysieren in ihrer Arbeit verschiedene Ansätze und kommen zu dem Fazit, dass keines der vorherigen Ansätze hinreichend genau auf Probleme mit Zeitreihen und Bilddaten eingeht. Daher entwickeln sie die *Knowledge Discovery in Time series and Image Data for Engineering Applications* (KDT-EA). In dieser legen sie einen besonderen Fokus auf die Schritte der Datenaufnahme, Datenvorbereitung und Modellierung.

Zwischen den einzelnen Prozessmodellen lassen sich Gemeinsamkeiten in der Struktur identifizieren (siehe hierzu weiterführend Tabelle 21). Demnach sind verschiedene Schritte zu durchlaufen, welche im Folgenden erläutert werden und zudem für Beschreibungen im weiteren Verlauf der Arbeit fungieren.

- *Ist-Analyse/Soll-Definition*: Im Zusammenhang des ersten Schritts wird das zu lösende Problem umfassend definiert sowie die Zielvorstellung charakterisiert.
- *Beschreibung der technischen Infrastruktur*: In diesem Schritt sind auf der Basis der vorherigen Ist-Analyse/Soll-Definition technische Ziele zu formulieren und die Netzwerkinfrastruktur zu beschreiben.
- *Datenaufnahme*: Hierbei erfolgt die Ausführung des Projektplans und die Aufnahme von Produktionsdaten.
- *Datenbewertung*: Im Zuge der Datenbewertung gilt es, einen Überblick über die bisher erfassten Daten zu gewinnen und diese umfassend zu analysieren. Dazu werden vor allem Werkzeuge der deskriptiven Statistik genutzt.
- *Datenvorbereitung*: Die Datenvorbereitung umfasst die Aktivitäten zur Erstellung des endgültigen Datensatzes. Zu beachten ist, dass entsprechende Methoden klassischerweise mehrfach durchlaufen werden müssen.
- *Algorithmeinsatz*: In diesem Zusammenhang wird der Datensatz in einen Trainings- und einen Testdatensatz unterteilt und im Anschluss verschiedene Algorithmen implementiert.
- *Evaluation der Ergebnisse*: Ziel der Evaluation ist eine Gegenüberstellung der durch ML-Algorithmen erzielten Ergebnisse sowie den in vorherigen Schritten erlangten Ergebnissen.
- *Verstetigung im Unternehmen*: Im letzten Schritt gilt es, die erarbeitete Lösung sowohl in technischer Sicht als auch mit Hinblick auf erzielte positive und negative Erkenntnisse zu verstetigen. Hierzu bedarf es einer langfristigen Integration in die Netzwerkinfrastruktur und unternehmensinterne Prozesse.

2.1.5 Zwischenfazit zu den Grundlagen des maschinellen Lernens

ML-Anwendungen stellen ein leistungsstarkes Instrument zur Auswertung aufgezeichneter Daten dar und bieten damit eine Grundlage zur Verbesserung von Produktionsprozessen. Für produzierende Unternehmen lassen sich dabei zahlreiche Anwendungsmöglichkeiten identifizieren. Diese sind zumeist dem Supervised und Unsupervised Learning zuzuschreiben. Von besonderer Relevanz in Forschung und Praxis sind dabei Anwendungen in der Instandhaltung. In der praktischen Umsetzung von ML-Anwendungen lassen sich jedoch einige Hürden identifizieren. Neben der notwendigen Datenaufnahme stellt der Kompetenz- und Zeitmangel in der Belegschaft zahlreiche Unternehmen vor Herausforderungen. Als oftmals Zuständige für Innovationsprojekte stellen Prozessverantwortliche und Teamleiter eine besonders zu betrachtende Zielgruppe dar. Ein mögliches Zielbild für diese Gruppe sind sogenannte Citizen Data Scientists. Diese weisen Grundkenntnisse verschiedener notwendiger Disziplinen für ML-Anwendungen auf und bieten damit das Potenzial, bestehende Hürden der Industrie zu lösen. Ein Ansatz zum Erreichen des Zielbilds stellen betriebliche Weiterbildungen dar. Somit lässt sich folgender Forschungsbedarf festhalten:

Forschungsbedarf 1: Entwicklung einer betrieblichen Weiterbildung, sodass Prozessverantwortliche und Teamleiter in der Produktion zu Citizen Data Scientists werden.

2.2 Grundlagen betrieblicher Weiterbildung

Bedingt durch den demographischen Wandel sowie einer gleichzeitig zunehmenden Wissensökonomie sind Unternehmen gefordert, Innovationen voranzutreiben (Kauffeld et al. 2018) und sich kontinuierlich an neue Begebenheiten anzupassen (Horvat und Som 2018). Dadurch werden neue Kompetenzanforderungen an die Mitarbeiter gestellt. Um bestehende Lösung hinsichtlich Relevanz einordnen und bewerten zu können, müssen sie fachlich und methodisch auf dem Stand der Technik bleiben. Lernen muss daher über die gesamte Erwerbszeit berufsbegleitend durchgeführt und von den Angestellten selbst verantwortet werden. (Metternich et al. 2018) Für Mitarbeiter ist es dabei essenziell, neben der Aufnahme von Faktenwissen an Handlungsfähigkeit zu gewinnen (Erpenbeck und Sauter 2013). Einen Hebel dazu stellen betriebliche Weiterbildungen dar.

In diesem Abschnitt werden die genannten Begriffe Wissen und Handlungsfähigkeit genauer erläutert und voneinander abgegrenzt, sowie weitere in diesem Zusammenhang relevante Terme eingeführt (Abschnitt 2.2.1). In Abschnitt 2.2.2 wird eine Übertragung in das betriebliche Lernen vorgenommen und hierzu verschiedene Konzepte erläutert. Im folgenden Abschnitt 2.2.3 werden Vorgehen präsentiert, um Schulungsmaterialien kompetenzorientiert zu gestalten. Der konsekutive Abschnitt 2.2.4 kombiniert Erkenntnisse der vorherigen Erläuterungen und legt relevante Kompetenzen zum Umgang mit ML-Anwendungen dar. Eine Analyse bestehender Weiterbildungsangebote zur Vermittlung der identifizierten Kompetenzen erfolgt daraufhin in Abschnitt 2.2.5. Abschnitt 2.2.6 zieht abschließend ein Zwischenfazit und leitet Forschungsbedarfe her.

2.2.1 Definition und Begriffsabgrenzung

Obwohl im täglichen Sprachgebrauch oftmals synonym verwendet (Abele et al. 2024), stellen Wissen, Handlungsfähigkeit und weitere artverwandte Begriffe im wissenschaftlichen Diskurs unterschiedliche Konzepte dar. Anhand von Abbildung 5 wird der Zusammenhang im Folgenden erläutert.

Wissen, als Grundlage der Konzepte, beschreibt die Aneignung von Informationen durch Lernen und umfasst eine Menge an Fakten, Theorien und Praktiken im Zusammenhang mit einem Arbeits- oder Studienfeld (Rat der Europäischen Union 2017). Wissen stellt also die Aufnahme von Zeichen, Daten und Informationen inklusive ihrer Kontextualisierung beziehungsweise Verarbeitung dar (North 2016). Es lässt sich darüber hinaus weiter systematisieren und in verschiedene Klassifikationen unterteilen (Tenberg 2011). So unterscheidet Anderson die beiden Klassen deklaratives und prozedurales Wissen (Anderson 2013). Ersteres ist dabei explizit und systematisiert, während zweiteres implizit und nur im Handeln ersichtlich ist (Tenberg 2011). Renkl greift die Begriffe auf und ergänzt sie um das konzeptionelle und das konditionale Wissen (Renkl 1994). Unter dem

konzeptionellen Wissen ist solches zu verstehen, welches zum Verständnis über Fakten und Vorgehensweisen dient. Das konditionale Wissen lässt sich als Zugriffswissen verstehen und beantwortet die Frage, wann und warum auf bestimmtes Wissen zugegriffen wird (Tenberg 2011). In Anlehnung an Renkl definiert Tenberg die Begriffe Professionswissen, Begründungswissen und Bezugswissen (Tenberg 2011). Da prozedurales und konditionales Wissen implizit und daher nicht konkretisierbar sind, versteht der Autor sie als Fertigkeit oder Fähigkeit (siehe unten).




Abbildung 5: Wissenstreppe nach North, eigene Darstellung in Anlehnung an North (2016)

Wie dargestellt, genügt die alleinige Aufnahme von Wissen insbesondere in Zeiten der Digitalisierung nicht aus (siehe Kapitel 1.1). Mehrwert aus Wissen entsteht erst, wenn Wissen in Können umgesetzt wird (North 2016). Kommt das Wissen also in die Anwendung, lässt es sich in Form von *Handeln* beobachten. Handeln äußert sich dabei durch Fähigkeiten und Fertigkeiten (siehe Abbildung 6). *Fähigkeiten* beschreiben die mittels bestimmter Anlagen oder Eigenschaften vorhandene Möglichkeit eines Individuums, gegebene Funktionen oder Anforderungen zu erfüllen und damit etwas zu leisten (Duden 2024a) und bilden damit psychische und physische Voraussetzungen (Jung 2010). Aufbauend darauf sind *Fertigkeiten* die Fähigkeit, Wissen im spezifischen Anwendungsfall anzuwenden und somit Aufgaben zu erfüllen sowie Probleme zu lösen (Rat der Europäischen Union 2017). Sie lassen sich gemäß letzterer Autoren in kognitive Fertigkeiten (logisches, intuitives und kreatives Denken) und praktische Fertigkeiten (manuelle Tätigkeiten, Einsatz von Methoden, Materialien oder Instrumenten) unterteilen. Um Wissen und Fertigkeit gewinnbringend aufzubauen, bedarf es zudem Motivation auf Seiten der Lerner (Graf und Edelkraut 2016; Jung 2010; Chryssolouris et al. 2013; North 2016). Auffällig ist, dass zwischen Wissen und dessen Anwendung in der Praxis oftmals eine Diskrepanz vorherrscht (Renkl 1994). Inhalte sind zwar verstanden worden, können jedoch nicht auf unbekannte Situationen übertragen und nicht gewinnbringend eingesetzt werden (Brandl 1997). Whitehead (1929) spricht in diesem Fall von trägem Wissen.

Erpenbeck et al. verstehen Wissen und Fertigkeiten darüber hinaus als Gegenstand von Qualifikationen (Erpenbeck et al. 2017) (siehe Abbildung 6). *Qualifikationen* wiederum sind formale Ergebnisse eines Bewertungs- und Validierungsprozesses, die erreicht werden, wenn eine Person Lernergebnisse nach vorgegebenen Standards erzielt (Rat der Europäischen Union 2017). Qualifikationen werden also in abgetrennten, normierbaren und

sukzessive abzuarbeitenden Prüfungssituationen erkennbar. Sie sind auf vorgegebene Zwecke gerichtet, beschränken sich auf spezifische Anforderungen und sind in der Folge fremdorganisiert und objektbezogen. (Erpenbeck et al. 2017) Für Unternehmen stellen Qualifikationen heutzutage daher oftmals ein zentrales Element zur Entwicklung von Mitarbeitern in der Produktion dar (Abele et al. 2024).




Abbildung 6: Zusammenhang von Wissen, Qualifikation und Kompetenz, in Anlehnung an Erpenbeck et al. (2017)

In Abgrenzung dazu sind *Kompetenzen* geistige oder physische Dispositionen zum selbstorganisierten Handeln. Sie umfassen verschiedene Fähigkeiten, um kreativ zu agieren und mit unklaren oder fehlenden Zielen umzugehen. (Erpenbeck et al. 2017) Individuen nutzen dabei erlangtes Wissen und gewonnene Fähigkeiten, um gegebene Situationen zweckorientiert zu lösen (North 2016). Im Kontrast zu Qualifikationen sind Kompetenzen subjektbezogen und haben einen ganzheitlichen Anspruch (Erpenbeck et al. 2017). Sie lassen sich dabei in vier Kompetenzklassen unterteilen, welche im Folgenden vorgestellt werden (Erpenbeck et al. 2017):

- *Personale Kompetenzen*: Die Fähigkeit, sich selbst einzuschätzen, konstruktive Einstellungen, Werte, Motive sowie Selbstbilder zu kreieren und im Bedarfsfall einzusetzen sowie weiterzuentwickeln.
- *Fachlich-methodische Kompetenzen*: Die Fähigkeit, fachliche und methodische Kenntnisse, Fähigkeiten und Fertigkeiten in die Bewältigung von Aufgaben einzubringen.
- *Sozial-kommunikative Kompetenzen*: Die Fähigkeit, kommunikativ und kooperativ zu handeln und sich somit gruppen- und beziehungsorientiert zu verhalten.
- *Aktivitäts- und umsetzungsorientierte Kompetenzen*: Die Fähigkeit, aktiv und selbstorganisiert zu agieren und entsprechende Aktionen im Kontext von Vorhaben und Plänen zu realisieren. Personale, fachlich-methodische und sozial-kommunikative Kompetenzen können hierbei zielorientiert in entsprechende Vorhaben integriert werden.

Die vorangegangenen Überlegungen zu Kompetenzen fasst die Definition des Europäischen Parlaments und des Rats der Europäischen Union (2008) zusammen. Für diese Arbeit wird entsprechend folgende Definition festgehalten:

Definition Kompetenz:

Die nachgewiesene Fähigkeit, Kenntnisse, Fertigkeiten sowie persönliche, soziale und methodische Fähigkeiten in Arbeits- oder Lernsituationen und für die berufliche und/oder persönliche Entwicklung zu nutzen.

Um Kompetenzen zielorientiert einzusetzen, wird darüber hinaus ein Rahmen an *Regeln*, *Normen* und *Werten* gefordert, welche das Verhalten eines Individuums unweigerlich beeinflussen (Erpenbeck et al. 2017). In letzter Konsequenz stellt das Vorhandensein von Kompetenzen in der Belegschaft einen Wettbewerbsvorteil für Unternehmen dar, welchen es mit Hinblick auf die Aufrechterhaltung der Wettbewerbsfähigkeit zu nutzen gilt (North 2016; Kauffeld und Grote 2002).

Im Kontrast zu Qualifikationen sind Kompetenzen nicht direkt sichtbar. Es kann lediglich mittels anderer Konstrukte auf sie geschlossen werden (Tisch et al. 2013; Tenberg 2011). Die Literatur unterteilt in Anlehnung an Chomsky (1965) daher zwei Ebenen: der Kompetenz eines Individuums, betitelt als Tiefenstruktur, und der *Performanz*, welche empirisch beobachtbar ist und als Oberflächenstruktur bezeichnet wird. Zwischen den beiden Ebenen laufen Transformationsprozesse ab. Diese erfolgen entweder in der Richtung Oberfläche – Tiefe und prägen sich durch Lernen aus oder aber in der Richtung Tiefe – Oberfläche und zeigen sich durch Handlungen. Qualifikationen stellen somit eine Überführung von Kompetenzen aus der Tiefenstruktur mittels Handlungen in Performanzen auf der Oberflächenstruktur dar (siehe Abbildung 7). (Jung 2010)




Abbildung 7: Zusammenhang von Kompetenz und Performanz, eigene Darstellung in Anlehnung an Jung (2010)

Mit Hinblick auf den in Abschnitt 1.1 beschriebenen Paradigmenwechsel von dem Erwerb von Faktenwissen hin zu Kompetenzerwerb (Erpenbeck und Sauter 2013), besteht Bedarf sowohl an Kompetenzvermittlung als auch an Kompetenzentwicklung. Dabei beschreibt die Kompetenzvermittlung einen angeleiteten Prozess, bei dem Instruktionen durch einen Lehrer vorgenommen werden. Im Kontrast umfasst die Kompetenzentwicklung Selbststeuerung durch den Lerner sowie aktive Wissenskonstruktion durch erlangte Erfahrungen. (Jung 2010)

2.2.2 Grundlagen des betrieblichen Lernens

Dieser Abschnitt überträgt die zuvor erläuterte Theorie auf die betriebliche Weiterbildung. Dazu werden zwei Lerntypologien vorgestellt und erörtert.

Der Literatur folgend lässt sich Lernen zunächst in formelles, informelles und non-formales Lernen unterscheiden (Dehnbostel 2016). *Formelles Lernen* findet klassischerweise in Einrichtungen statt, in denen Qualifikationen erreicht werden können (Allgemeinbildende Schulen, Berufsschulen oder Universitäten) (Gutschow 2020). Es läuft dabei strukturiert und geplant ab (Heyse und Erpenbeck 2010) und ist didaktisch durch geschulte Personen aufbereitet und durch Lernziele gerichtet (Dehnbostel 2016). Insofern geeignet, kann es auch medial durch internetbasiertes Training, Videos, E-books oder Serious Games ergänzt werden (Erpenbeck et al. 2016). *Informelles Lernen* hingegen findet zumeist ungeregelt statt, wodurch es nicht intendiert ist und auch nicht zu einem definierten Abschluss führt (Gutschow 2020). Es erfolgt daher außerhalb von Bildungseinrichtungen und umfasst auch das Lernen im Prozess der Arbeit (Heyse und Erpenbeck 2010). Ein Lerner gewinnt dabei Fähigkeiten zur Situationsbewältigung und Problemlösung (Dehnbostel 2016). Im Unternehmensalltag kann informelles Lernen durch Lerntagebücher oder Wikis erfasst werden (Erpenbeck et al. 2016). *Non-formales Lernen* letztlich ist ähnlich dem formalen Lernen geplant und strukturiert und kann final mit einem Zertifikat bescheinigt werden. Es findet außerhalb des öffentlich-rechtlichen Bildungssystems in Unternehmen oder bei Bildungsträgern statt. Auf dem Arbeitsmarkt können die Zertifikate jedoch von Vorteil sein. (Dehnbostel 2016; Gutschow 2020) Tabelle 2 fasst die Lernwege zusammen.

Mit Hinblick auf Kompetenzen für die Industrie 4.0 lässt sich hinsichtlich der Lernwege eine Diskrepanz beobachten. So findet Lernen vor allem informell statt (Schiersmann 2007). Unternehmen setzen jedoch zur Weiterbildung vorrangig auf formales Lernen (acatech 2016).

Tabelle 2: Wege der Kompetenzentwicklung, eigene Darstellung in Anlehnung an Blumberg und Kauffeld (2021)

Beschreibung	Formales Lernen	Informelles Lernen	Non-formales Lernen
Organisationsgrad	Organisiert und strukturiert	Nicht organisiert	Eher organisiert
Lernintention	Intendiertes Lernen mit expliziten Lernzielen	Nicht intendiert, sondern eher beiläufig	Teilweise intendiert, Lernziele teilweise explizit formuliert
Lernort	Meist in Seminaren und Kursen in Bildungseinrichtungen oder Unternehmen	Soziale Interaktion, Reflexion eigenen Handelns	Tendenziell im Prozess der Arbeit durch Anlernen und Unterweisungen
Beispiele	Betriebsexterne Kurse oder Betriebsinterne Kurse	Analoges oder digitales Lernen im Prozess der Arbeit	Analoges oder digitales Anlernen, Unterweisungen, Selbstorganisiert, in Lernfabriken

Betriebliches Lernen lässt sich weiterhin in drei Formen des sogenannten arbeitsbasierten Lernens unterteilen (siehe Abbildung 8) (Dehnbostel 2009). Beim *arbeitsorientierten Lernen* findet Lernen an dedizierten Lernorten statt. Arbeitsaufgaben und -prozesse werden so genau wie möglich simuliert. Im Vordergrund steht der Lernprozess, was eine Diskrepanz zum realen Umfeld zur Folge haben kann (Dehnbostel und Schröder 2017). Einen Ansatz für das arbeitsorientierte Lernen stellen unternehmensexterne Lernfabriken dar (Abele et al. 2024). Beim *arbeitsverbundenen Lernen* sind Lernort und Arbeitsplatz zwar physisch getrennt, durch die Arbeitsorganisation aber miteinander verbunden. So kann es beispielsweise einen Lernbereich in der Nähe einer Produktionslinie geben, an dem Mitarbeiter in Qualitätszirkeln oder Praktika lernen. (Dehnbostel und Schröder 2017) Eine weitere Möglichkeit bieten unternehmensinterne Lernfabriken (Dehnbostel 2018a). Beim letztlichen *arbeitsintegrierten Lernen* (AiL) sind Lernort und Arbeitsplatz identisch, wobei das Lernen am Arbeitsplatz oder im Prozess der Arbeit stattfindet (Dehnbostel und Schröder 2017). Beispiele für das AiL sind das digitale Lernen am Arbeitsplatz oder Lerninseln sowie Coaching durch erfahrene Kollegen oder Vorgesetzte (Dehnbostel 2018a). Lernern ist es somit möglich, erworbene Kenntnisse und Fähigkeiten direkt bei ihrer Arbeit anzuwenden und dadurch die Verbindung zwischen Lernprozess und Erfüllung der Arbeitsaufgabe zu stärken (Abele et al. 2024). Für das AiL lassen sich zusammenfassend folgende Vorteile festhalten:

- a. Es unterstützt den Transfer und die Anwendung von disziplinärem Wissen in Arbeitssituationen (Bahl und Dietzen 2019). Gelerntes muss somit nicht nachträglich in den eigenen betrieblichen Alltag übertragen werden (Bigalk 2006; Cedefop 2016).
- b. Es erhöht die Gesundheit und Motivation von Beschäftigten und erlaubt es ihnen, den digitalen Wandel im Unternehmen mitzugestalten (Tisch et al. 2021).
- c. Es ermöglicht selbst-bestimmtes Lernen im Lerntempo der Lerner (Dehnbostel 2020).
- d. Personen mit unterschiedlichem Lernniveau können zusammen lernen, wodurch Lernen gemäß Mitarbeiterbedarf erfolgt (Stork et al. 2020).
- e. Es fördert die Selbstorganisation von Angestellten (Stork et al. 2020).
- f. Unternehmen weisen ein verbessertes Arbeitsklima auf, da mehr abteilungs- und standortübergreifende Interaktion vorhanden ist (Stork et al. 2020).
- g. Es bietet mehr Flexibilität und geringere Kosten für Unternehmen (Richter und Mühlenbrock 2020), da keine Freistellung für Schulungen notwendig sind (Cedefop 2016; Hacker 2015) und Anfahrt, Unterbringung und Verpflegung entfallen (Friebe 2005).
- h. Lernen richtet sich an Unternehmenszielen aus (Dehnbostel und Schröder 2017).
- i. Die Fluktuation sinkt und die Mitarbeiterakquise verliert dadurch an Relevanz (Cedefop 2016).

Insbesondere für das Lernen in Bezug auf ML-Anwendungen in der Produktion bietet AiL einige Vorteile. Im Vergleich zum Besuch von externen Schulungen können

Mitarbeiter beispielsweise relevante Datenquellen, wie Produktionsprozesse, besser verstehen. Außerdem können sie leichter auf Informationen zugreifen und somit fundiertere Entscheidungen treffen. Folglich sind Datenanalysen kostengünstiger und zuverlässiger. (Bianchini und Michalkova 2019)




Abbildung 8: Formen des arbeitsbasierten Lernens, eigene Darstellung in Anlehnung an Dehnbostel (2009)

Um AiL in der betrieblichen Praxis umzusetzen, bedarf es unterstützender Maßnahmen auf organisatorischer Ebene. Zunächst ist eine lernförderliche Unternehmenskultur vonnöten. Demzufolge werden seitens des Unternehmens finanzielle, materielle sowie personelle Ressourcen bereitgestellt (Jokovic et al. 2017). Flache Hierarchien mit einer Projektorganisation und weiten Entscheidungsspielräumen für die Mitarbeiter unterstützen das Lernen zudem (Friebe 2005). Weiterhin muss den Mitarbeitern Zeit zum Lernen eingeräumt werden (Jokovic et al. 2017). Es bedarf hierzu der Möglichkeit zu Freistellungen, einer Flexibilisierung der vertraglichen Arbeitszeit, Time-Sharing oder Überstundenabbau (Friebe 2005). Zudem müssen die Lerninhalte gegenüber den Arbeitssituationen authentisch und situiert sein (Jokovic et al. 2017; Dehnbostel und Schröder 2017). Dazu ist es notwendig, dass zu erlernende Inhalte relevant für den Arbeitsalltag sind und Lernen in Form sogenannter Community of Practices (CoP) (Lave und Wenger 1991; Wenger 2008) stattfinden kann. Apt et al. (2018b) sprechen in diesem Zusammenhang vom kooperativen Lernen. Es erlaubt den Autoren zufolge, dass Lerninhalte besser verstanden werden. Der Mehrwert durch AiL steigt weiterhin, wenn Unternehmen soziale Unterstützung bereitstellen. Neben der Ermöglichung von CoP stellt das Vorhanden sozialer Netzwerke im Unternehmen einen Befähiger dar (Friebe 2005). Auch eine veränderte Führungskultur in Form von transformationaler Führung, bei der die Führungskraft als Coach fungiert, wirkt sich positiv aus (Ribbat 2020). Zur Verhinderung von trägem Wissen bedarf es multipler Kontexte (Jokovic et al. 2017). Gelerntes ist somit übertragbar auf ähnliche Anwendungsfälle. Letztlich sollten Lerner selbstbestimmt und eigenverantwortlich lernen können (Jokovic et al. 2017; Dehnbostel und Schröder 2017). Eine Harmonisierung von Unternehmenszielen und individuellen Zielen, beispielsweise durch Learning Contracts (Dyer et al. 2018) oder durch die Definition von Lernzielen (Friebe 2005), stellen dafür eine notwendige Voraussetzung dar. Zusammenfassend kann festgehalten werden, dass AiL geprägt sein sollte von Subjektorientierung auf den Lerner, Selbstregulierung durch den Lerner, Prozessorientierung auf reale Anwendungsfälle, Erfahrungslernen

durch Handlungselemente sowie eine Kombination von informellem, nicht-formalem und formalem Lernen (Dehnbostel 2015). Weiterhin bedarf Lernen der Reflexion, um Erlerntes von der Oberflächen- in die Tiefenstruktur zu überführen. Dazu eignet sich die Sequenz von Aktion – Erfahrung – Reflexion. (Dehnbostel und Schröder 2017)

2.2.3 Schulungsgestaltung für die betriebliche Weiterbildung

Wie im vorherigen Abschnitt dargestellt, erfordert die Gestaltung von Schulungen in der betrieblichen Weiterbildung sowohl die Einbeziehung von Theorieinhalten als auch an praxisorientierter Elemente. Die Literatur kennt dazu verschiedene Vorgehen, von denen zwei in diesem Abschnitt vorgestellt werden.

Das erste Vorgehen basiert auf den Vorarbeiten von Abele et al. (2015a). Schulungen bestehen darin aus einer *Einführung*, *Systematisierungsaktivitäten*, *Erschließungs-* respektive *Erprobungsaktivitäten*, und enden mit einer *Reflexion* und einer etwaigen *Kontrolle*. Auf Basis von Abele et al. (2015a) und Tenberg (2011) werden die fünf Aktivitäten vertiefend eingeführt. Die Einleitung kennzeichnet den Beginn einer neuen Sequenz. Diese kann durch eine kurze Hinführung zum neuen Thema oder eine Frage an die Lerner realisiert werden. Systematisierungsaktivitäten umfassen das Erfassen, Vergleichen oder Abstrahieren fachlicher Informationen sowie die Durchführung oder Auswertung von Versuchen. Bestehendes Wissen soll aktiviert, überprüft oder erweitert werden. Im Zusammenhang von Erschließungs- und Erprobungsaktivitäten lassen sich Lernaktivitäten in Verbindung mit beruflichen Problemstellungen verstehen. Lerner sollen dazu eigene Ziele bilden und deren Fortschritt überprüfen. Anders als bei der Erschließung werden in der Erprobung keine neuen Gebiete erschlossen, sondern bekannte vielmehr handlungstechnisch vertieft (Tisch 2018). In der Reflexion können Lerner selbst feststellen, ob sie Fehler gemacht haben und etwaige Inhalte noch nicht verstanden haben. Den optionalen Abschluss stellt die Kontrolle dar. Die Erreichung der definierten Lernziele wird in diesem Kontext überprüft.

In Abhängigkeit der Reihenfolge von Systematisierung und Erprobung/Erschließung lassen sich die drei Herangehensweisen Problem-Pull, Theory-Push (Cachay und Abele 2012) und Reflexion-First (Tisch et al. 2015) unterscheiden. Diese werden im Folgenden in Anlehnung an letztere Autoren sowie an Tenberg (2011) kurz vorgestellt. Beim *Problem-Pull* beginnt eine Lernsequenz mit einem realen oder simulierten Problem, bei welchem unter Umständen bereits erste Problemlösungsversuche vorgenommen werden (Erschließungsaktivitäten). Im Rahmen der Systematisierung erfolgt daraufhin eine Theorieschulung. Im Anschluss erproben Teilnehmer neu erlerntes Wissen an einem weiteren Problem. Problem-Pull eignet sich insbesondere, wenn Teilnehmer keine oder unzureichende Erfahrung mit den jeweiligen Problemen haben. In Abgrenzung dazu steht beim *Theory-Push* die Vermittlung von Theorie am Beginn der Lernsequenz. Das Wissen wird im Anschluss in einem realen Anwendungsbeispiel getestet (Erprobungsaktivitäten). Theory-Push ist insbesondere dann anwendbar, wenn Teilnehmer bereits entsprechende Probleme in ihrem eigenen Arbeitsbereich erlebt haben und die Bedeutung des Themas

erkennen. Lernen in Form von *Reflexion-First* beginnt mit einer Diskussion und Reflexion bereits bestehenden Wissens und Problemlösungen und geht in Theory-Push oder Problem-Pull über. Es eignet sich, wenn Lerner bereits Erfahrungen mit der Lösung von Problemen in dem jeweiligen Anwendungsbereich gesammelt haben. Abbildung 9 stellt die Möglichkeiten Theory-Push und Problem-Pull gegenüber.




Abbildung 9: Mögliche Abfolgen von Aktivitäten, Darstellung in Anlehnung an Enke et al. (2016) und Glass (2021)

Ein anderes Vorgehen schlagen Erpenbeck et al. (2016) vor. Sie beschreiben einen Ansatz zur Realisierung von *sozialem Lernen* am Arbeitsplatz, welcher auf das arbeitsintegrierte Lernen übertragbar ist. Er erstreckt sich über die vier Phasen Vorphase, Kickoff, Selbstlernphase und dem eigentlichen Workshop. Die Vorphase hat zum Ziel, etwaige Rahmenbedingungen zu legen und Vorbereitungen zu treffen. Im Kickoff wird daraufhin eine Einführung in die Lernkonzeption gegeben und relevante Lernmaterialien vorgestellt. Innerhalb der selbstorganisierten Lernphase verknüpfen die Teilnehmer verschiedene Lernprozesse zu einem übergeordneten Kompetenzentwicklungsprozess. Mittels Theorieinhalten und sozialen Interaktionen in CoPs erfahren sie dabei eine Kompetenzentwicklung. In einem abschließenden Workshop erfolgt eine Reflexion der Selbstlernphase. Zudem werden offene Fragen geklärt und Projektergebnisse vorgestellt. Abbildung 10 stellt das Vorgehen grafisch dar.




Abbildung 10: Vorgehen zum sozialen Lernen am Arbeitsplatz, eigene Darstellung in Anlehnung an Erpenbeck et al. (2016)

2.2.4 Kompetenzen für ML-Anwendungen in der Produktion

In diesem Abschnitt wird der Bedarf nach geeigneten ML-Kompetenzen für die in 2.1.3 erarbeitete Zielgruppe näher beleuchtet. Im Gegenzug werden solche mit Fokus auf Data Scientists oder Produktionsmitarbeiter außen vor gelassen. Zur Ermittlung relevanter Kompetenzen wird eine Literaturrecherche durchgeführt. Die Ergebnisse der Recherche werden mit Hinblick auf die weitere Arbeit in der Folge detailliert vorgestellt. Eine Liste aller ermittelten Lernziele findet sich abschließend in Tabelle 3.

André et al. (2021a) untergliedern drei Hauptkompetenzen: Domänenwissen und entsprechende Weiterentwicklungsmöglichkeiten, Entwicklung von und Umgang mit ML-Anwendungen sowie Gestaltung des Kontexts von ML-Anwendungen. Diese sind je nach Rolle unterschiedlich ausgeprägt. Für die vorliegende Arbeit wird die von den Autoren eingeführte Rolle der Industriemeisterin als relevant erachtet und daher hier zusammenfassend dargelegt. Sie ist eine technische Führungskraft und fungiert als Schnittstelle zwischen Management- und Fertigungsebene. Dazu benötigt sie Anpassungsfähigkeit an neue Technologien. Auch die Fachkompetenz erfährt Veränderungen. So muss sie als Führungskraft fachlich in der Lage sein, ihre Mitarbeiter in der Anwendung mit der ML-Lösung anzuleiten. Dazu bedarf es der Kompetenz in der Mensch-Maschine-Interaktion. Um ihre Vorbildfunktion ausführen zu können, ist weiterhin ein grundlegendes Wissen über ML-Anwendungen notwendig. Einfache Probleme im Umgang mit ML-Anwendungen soll die Meisterin dabei selbstständig lösen können, für komplexere allerdings zielorientiert auf Entwickler zugehen können. Neben Problemlösungskompetenz ist daher entsprechende Kommunikationsfähigkeit notwendig. Gesammelte Daten und Informationen aus ML-Anwendungen sind zu analysieren und zu interpretieren (System- und Prozesskompetenz), um auf deren Grundlage Entscheidungen für Verbesserungsmaßnahmen zu treffen. Bedingt durch den Einsatz von ML-Anwendungen kommen zudem neue Entscheidungsfelder auf, was Veränderungen in der Entscheidungskompetenz nach sich zieht. Letztlich stellen sich neue Anforderungen an die Reflexionskompetenz, da sie nun auch den Einsatz der ML-Anwendung beurteilen muss.

Peifer et al. (2022) beschreiben Kompetenzen in Bezug auf ML-Lösungen mit spezifischem Fokus auf Führungskräfte in industriellen Unternehmen. Diese untergliedern sie in vier Cluster: Strategischer Transformationsprozess, Qualifikation und Kompetenzen, Kultur und Mensch-Maschine-Interaktion. Demnach sollten Führungskräfte erstens in der Lage sein, Change-Prozesse anzustoßen und zu koordinieren. Zweitens bedarf es eines Grundlagenwissens über die Technologie. Dabei ist kein detailliertes Wissen notwendig. Vielmehr sollten Führungskräfte grundlegend verstehen, wie entsprechende Lösungen funktionieren. Ein besonderer Fokus ist in diesem Zusammenhang auf hohe Datenqualität und die Ergebnisse von Modellen zu legen. Auch bedarf es Kenntnisse über die betrachteten Prozesse, um etwaige Risiken durch die Implementierung einzuordnen. Zudem müssen Führungskräfte in zunehmendem Maße als Schnittstelle zwischen Mitarbeitern und ML-Anwendung fungieren. Dazu müssen sie insbesondere entscheiden können, welche Aufgaben zukünftig durch ML-Anwendungen übernommen werden und welche weiterhin durch Menschen. Hierzu müssen sie die jeweiligen Stärken ermessen können. Letztlich müssen sie ethische Aspekte einbeziehen. Hierunter fallen die Selbstbestimmung, Gerechtigkeit sowie Schutz der Privatsphäre und der Persönlichkeit.

Rokoss et al. (2021) legen ML-Kompetenzen dar, welche in ihrer Schulungsumgebung adressiert werden. Sie unterscheiden dabei fünf Hauptkompetenzen. Diese umfassen die Handhabung der ML-Theorie im Kontext der Produktion, Vorbereiten eines Datensatzes für ML und Einrichtung eines ML-Modells, Umsetzen des ML-Modells sowie die

Anwendung von ML auf neue produktionsbezogene Probleme. Die erste Hauptkompetenz wird daraufhin weiter charakterisiert durch Teilkompetenzen wie Grundlagenwissen über ML und Industriesensoren oder dem Vergleichen verschiedener Algorithmusergebnisse, insbesondere mit Hinblick auf statistische Methoden. Die zweite Hauptkompetenz umfasst sämtliche Aspekte im Umgang mit Daten (Sammeln von Daten, Untersuchen der Datenqualität, Auswahl der richtigen Daten unter anderem). Weiterhin müssen Anwender in der Lage sein, Algorithmen selbstständig zu entwickeln. Dazu sollen sie verschiedene Algorithmen auswählen, Leistungsmetriken verwenden und das Ergebnis eines Algorithmus gegen ursprünglich definierte Ziele spiegeln. Insofern erforderlich, bedarf es nach Aussage der Autoren entsprechender Kompetenzen, welche sich mit der Verstetigung befassen. Darunter fallen verschiedene methodische Schritte. Letztlich soll das Erlernte auf neue Anwendungsfälle übertragen werden können. Dazu muss die Zielgruppe Probleme in Bezug auf ihre Umsetzbarkeit durch ML-Anwendungen evaluieren können, ein Bewusstsein über Datenverzerrung aufweisen und die Auswirkungen von ML-Entscheidungen evaluieren können.

Der Autor dieser Arbeit unternimmt in Rosemeyer et al. (2022) eine Literaturrecherche und eine Fragebogenstudie unter Industrievertretern, um verschiedene ML-Kompetenzen zu ermitteln. Ihre Ergebnisse klassifizieren sie in sieben Hauptkompetenzen und 26 zugeordnete Teilkompetenzen. Aufgrund des hohen Umfangs werden an dieser Stelle nur die Hauptkompetenzen vorgestellt. Den Autoren zufolge ist es für die adressierte Zielgruppe zunächst notwendig, mögliche ML-Anwendungsfälle für die Produktion ermitteln zu können. Ist dies getan, müssen sie weiterhin den Implementierungsaufwand im Zuge der Projektierung abschätzen, mögliche Kosten(-treiber) aufstellen sowie die Projekte leiten können. Vorteile entsprechender Lösungen müssen sie zum einen in Richtung des Top-Managements und zum anderen in Richtung ihrer Mitarbeiter erklären können. Hierzu bedarf es interdisziplinärer Kommunikationskompetenz. Insbesondere müssen sie in der Lage sein, ihr zugeteiltes Team sinnvoll mit Hinblick auf ML-Anwendungen zu strukturieren. Außerdem besteht die Notwendigkeit, einfache ML-Algorithmen zu verstehen und erklären zu können. Letztlich sollen sie nach Erkenntnis der Autoren erzielte Ergebnisse einzuordnen wissen.

Auch Salminen et al. (2024) führen eine empirische Analyse durch und ermitteln somit notwendige ML-Kompetenzen. Ihre Erkenntnisse umfassen Bedarf nach konkreten Anwendungsfällen und Grundlagenwissen einerseits. Andererseits halten sie Kompetenzen zum ethischen Umgang von ML-Anwendungen fest, für den auch Regeln im Zuge der Nutzung relevant sind. Außerdem identifizieren sie in der Industrie eine Unsicherheit darüber, wofür ML-Lösungen eingesetzt werden können und wer sie nutzen sollte.

Zwischen den vorgestellten Ausarbeitungen lassen sich einige Gemeinsamkeiten festhalten. So beschreiben alle fünf betrachteten Artikel, dass der Zielgruppe theoretische Grundlagen von ML-Anwendungen vermittelt werden müssen. Dabei sollten sie verschiedene mögliche Anwendungsfälle in Produktionsumgebungen kennen. Zum Zwecke der Umsetzung sollte die Zielgruppe relevante Sensoren nennen können. Konsekutiv

sollten sie aufgenommene Daten auf ihre Verwendbarkeit zu beurteilen wissen und in der Lage sein, diese zu interpretieren. Gleichmaßen sollten sie durch Algorithmen erzielte Ergebnisse interpretieren und gegen definierte Ziele spiegeln können. Auf Basis dessen lässt sich abschließend die Umsetzung eines verwendeten Modells reflektieren.

Tabelle 3: Übersicht über ermittelte Kompetenzen für die Zielgruppe

Lernziel/Kompetenz	Quelle
Anpassungsfähig sein an veränderte personelle und organisatorische Abläufe	André et al. (2021a); Peifer et al. (2022)
Fachliche Kompetenz über das Arbeitsfeld aufweisen	André et al. (2021a); Rokoss et al. (2021)
Mensch-KI-Interaktion begreifen und Aufgaben daraus ableiten	André et al. (2021a); Peifer et al. (2022); Rokoss et al. (2021)
Grundlagenwissen über ML-Anwendungen aufweisen	André et al. (2021a); Peifer et al. (2022); Rokoss et al. (2021); Salminen et al. (2024)
Problemlösungskompetenz bei aufkommenden Störungen im Kontext der ML-Implementierung aufweisen	André et al. (2021a)
Interdisziplinäre Kommunikationskompetenz in Bezug auf ML-Anwendungen aufweisen (hinsichtlich Top-Management, Mitarbeiter, weitere Stakeholder)	André et al. (2021a); Peifer et al. (2022); Rosemeyer et al. (2022)
Verständnis über die Prozesskette mitbringen	André et al. (2021a); Peifer et al. (2022); Rokoss et al. (2021)
Entscheidungen in Bezug auf den eigenen Arbeitsbereich treffen	André et al. (2021a); Peifer et al. (2022)
Reflexion des umgesetzten ML-Anwendungsfalls vornehmen	André et al. (2021a); Rokoss et al. (2021)
Change Management Prozesse koordinieren	Peifer et al. (2022)
Erstellung eines geeigneten Datensatzes vornehmen	Peifer et al. (2022); Rokoss et al. (2021)
Ethische Aspekte in ML-Modelle einbeziehen	Peifer et al. (2022); Salminen et al. (2024)
Ergebnisse von ML-Modellen interpretieren	Rokoss et al. (2021); Rosemeyer et al. (2022)
Implementierung von ML-Anwendungen planen und entsprechende Schritte anleiten	Rokoss et al. (2021); Rosemeyer et al. (2022)
Verschiedene (einfache) Algorithmen des maschinellen Lernens verstehen	Rokoss et al. (2021); Rosemeyer et al. (2022)
Mögliche ML-Anwendungsfälle für die Produktion identifizieren	Rokoss et al. (2021); Rosemeyer et al. (2022); Salminen et al. (2024)
Geeignete Sensoren und Sensorsignale auswählen	Rosemeyer et al. (2022)
Risiko Management durchführen	Rosemeyer et al. (2022)

2.2.5 Weiterbildungsangebote zu ML-Anwendungen in der Produktion

In diesem Abschnitt wird weiterhin ermittelt, welche Weiterbildungsmöglichkeiten zum gegenwärtigen Zeitpunkt für die in Abschnitt 2.1.3 festgelegte Zielgruppe bestehen, um die zuvor beschriebenen Kompetenzen zu erlangen.

In ihrer Publikation führen André et al. (2021b) eine Umfrage unter betrieblichen Fach- und Führungskräften durch, um zu ermitteln, wie sich Unternehmen aktuell zum Thema ML weiterbilden. Sie identifizieren, dass Weiterbildungsbedarf vornehmlich für Fach- und Führungskräfte besteht, während gering Qualifizierte und Leiharbeiter eher selten einbezogen werden. Qualifizierungsmaßnahmen werden dabei bevorzugt arbeitsverbunden oder -integriert durchgeführt. Diese werden überdies durch digitale Formate ergänzt. Eine Erläuterung, wie genau die Qualifizierungsmaßnahmen und die digitalen Formate aussehen, liefern die Autoren jedoch nicht. Die Erkenntnisse von André et al. stehen dabei den Ausführungen anderer Autoren (siehe Kapitel 1) entgegen, welche darlegen, dass zum gegenwärtigen Zeitpunkt ein Bedarf an arbeitsintegrierten Lernformen für ML-Anwendungen besteht. Um vertiefend zu klären, welche Weiterbildungsangebote bereits vorliegen, werden in der Folge verschiedene Ansätze untersucht. Zunächst wird ein Fokus auf Weiterbildungen für CDS gelegt. Weiterhin erfolgt eine Literatur- und Internetrecherche mit Fokussierung auf die Zielgruppe der Prozessverantwortlichen und Teamleiter. Dabei orientieren sich die Ergebnisse an den Ausführungen von Haselberger (2023)⁷. In der Konsequenz kann die Divergenz der angeführten Erkenntnisse genauer beleuchtet werden.

2.2.5.1 Weiterbildungsangebote zu Citizen Data Scientists

Deuse et al. (2021) stellen einen Demonstrator in einer Lernfabrik vor, anhand dessen Studenten die Grundlagen von ML-Verfahren praktisch erlernen können. Sie nehmen dabei die Rolle eines CDS ein und sollen Daten aus unterschiedlichen Quellen in der Interaktion mit Domänenexperten analysieren. IT-Experten unterstützen sie daraufhin bei dem Aufbau einer ML-Pipeline. Die Evaluation nehmen die CDS darauffolgend mit verschiedenen Stakeholdern vor, bevor sie letztlich die Ergebnisse dem Management präsentieren.

Merkelbach et al. (2022) basieren ihre Arbeit auf dem CRISP-DM und entwickeln dieses weiter. Dazu legen sie einen besonderen Fokus auf das Training von Domänenexperten als ML-Entwickler, welches einen dedizierten Prozessschritt zwischen Datenverständnis und Datenvorbereitung einnimmt. Ein in der Ausarbeitung eingeführter Coach stellt dazu notwendige Voraussetzungen auf und recherchiert relevante Weiterbildungen. Das Modell evaluieren sie final anhand einer Simulation mit historischen Daten in arbeitsverbundener Weise.

Mullarkey et al. (2019) entwickeln ein Schulungsprogramm über 16 Wochen für die Erwachsenenbildung und greifen dazu auf das projektbasierte Lernen zurück. Teilnehmer beginnen das Projekt mit der Zieldefinition. Am Ende des Programms versuchen sie, das Projekt mit Hilfe der im Verlauf erlernten Werkzeuge und Techniken abzuschließen und

⁷ Diese studentische Arbeit wurde im Rahmen der vorliegenden Dissertation betreut. Fragestellung und Methodik wurden dabei durch den Betreuer und Autor dieser Arbeit vorgegeben. Die Erarbeitung der Inhalte erfolgte in enger Abstimmung in regelmäßigen Gesprächen, Treffen und Emails.

somit das ursprüngliche Ziel zu erreichen. Jedes Modul der Weiterbildung umfasst mehrere praktische Übungen, die es den Teilnehmern ermöglichen, die erlernten Werkzeuge und Techniken unmittelbar auszuprobieren. Das Lernen findet dabei arbeitsverbunden statt.

Zusammenfassend lässt sich festhalten, dass bereits erste Ansätze zur Befähigung von Domänenexperten im Themenfeld ML vorliegen, welche sie zu CDS ausbilden. Diese lassen sich dem arbeitsverbundenen oder arbeitsorientierten Lernen zuordnen. Dabei erfolgt das Lernen entweder in einer Lernfabrik oder in Simulationen im Unternehmen.

2.2.5.2 Ergebnisse der Literaturrecherche

In einer Literaturrecherche, welche im Rahmen dieser Arbeit durchgeführt wurde, konnten in Summe 13 Weiterbildungsmaßnahmen zum Thema KI und ML für die erläuterte Zielgruppe ermittelt werden. Von diesen entstammen zwei von dem Autor dieser Arbeit selbst. Da sie in den folgenden Kapiteln näher erörtert werden, werden sie hier von der Beschreibung ausgeschlossen. Drei weitere Ansätze fokussieren Produktionsmitarbeiter, welche nicht im Fokus der Arbeit stehen. Die verbleibenden neun Ansätze werden in der Folge vorgestellt.

Azevedo und Almeida (2021) entwickeln ein digitales Schulungsprogramm, welches sich speziell an industrielle Entscheidungsträger richtet. Es stellt eine Mischung aus selbstgesteuerten Lernmethoden und aktuellem Wissen in Form von Videos dar. Dies wird unterstützt durch reale Anwendungsbeispiele und Fallstudien.

Daniyan et al. (2020) entwickeln einen Lernansatz, in welchem das Lernen in der Instandhaltung eines Eisenbahnunternehmens vorgenommen wird. Dazu setzen sie auf eine Lernfabrik, welche arbeitsverbundenes Lernen erlaubt. Sie erarbeiten fünf Schulungsmodule, in denen ML-Verfahren mit dem Ziel eingesetzt werden, Temperaturschwankungen und die verbleibende Nutzungsdauer von Radlagern eines Eisenbahnwagens zu prognostizieren.

Eder et al. (2021) beschreiben die Entwicklung eines interaktiven Lehrkonzepts für digitale Themen in Lernfabriken. Dazu präsentieren sie einen Workshop zur Datenanalyse auf Basis bestehender Lehrmethoden. In diesem verwenden Teilnehmer simulierte Daten, um erlernte Datenanalysetechniken praktisch anzuwenden und branchenspezifische Fragestellungen zu beantworten.

Eusterwiemann et al. (2021) beschreiben, wie Lernfabriken dazu dienen, Wissen über innovative, technologische Lösungen auf anschauliche und anwendungsbezogene Weise zu vermitteln. Sie zeigen, wie Anforderungen für die Gestaltung von Schulungsprogrammen unter Zuhilfenahme des CRISP-DM abgeleitet werden können. Als Ergebnis wird ein Ansatz zur Vermittlung grundlegender Prinzipien von ML-Anwendungen vorgestellt.

Fahle et al. (2022) stellen ein dreistufiges Konzept zur Integration menschenzentrierter ML-Anwendungen in Lernfabriken vor. Auf oberster Ebene wird beispielsweise die iterative Entwicklung eines menschenzentrierten ML-Arbeitssystems präsentiert. Die

zweite Ebene konzentriert sich auf individuelle Kompetenzen. Auf der untersten Ebene werden Workshops in drei spezifischen Modulen durchgeführt. Hierzu werden verschiedene Personas berücksichtigt. Innerhalb der Workshops werden praktische Anwendungen mit Reflexionsphasen verknüpft.

Manettas et al. (2023) entwickeln ein Trainingsszenario zur Vermittlung von Fähigkeiten für die prädiktive Instandhaltung innerhalb von Produktionsumgebungen. Dazu setzen sie auf Blended Learning bestehend aus asynchronem digitalem Lernen und synchronem Lernen in einer Lernfabrik. Die Lerner beginnen ihre Lernreise mit der Auswahl eines personalisierten Lernpfades, der eine erste Interaktion mit der Thematik ermöglicht und auf die digitalen und manuellen Erfahrungen der Lerner, sowie auf dessen Sprachkompetenzen eingeht. Nach der digitalen Phase folgen Übungen in der Lernfabrik, bei denen das theoretische Wissen mit Probanden der Industrie angewendet wird.

Rokoss et al. (2021) beschreiben, wie Lernfabriken beim Erwerb von ML-Kompetenzen für produktionsbezogene Planungs- und Steuerungsaufgaben helfen können. Zur Realisierung ihrer Beschreibungen entwickeln die Autoren zudem einen Schulungsansatz, der Teilnehmer befähigt, wesentliche ML-Aspekte im Produktionsumfeld zu erlernen und anzuwenden. Mittels des Schulungsansatzes wird es den Teilnehmern ermöglicht, Kompetenzen zu erwerben, die die Entwicklung einer ML-basierten Anwendung für ein neues Problem im Zusammenhang mit der Produktion erfordern.

Der Ansatz von Rueckert et al. (2021) und Papenberg et al. (2022) kombiniert die Implementierung eines temporären Lernbereichs mit regelmäßigen Workshops. Die Autoren beschreiben ihr Konzept als eine Lernfabrik, die für eine begrenzte Zeit in Unternehmen implementiert werden kann. Im Rahmen der Workshops erarbeiten Anwender und Entscheidungsträger gemeinsam einen ML-Demonstrator. Durch die aktive Partizipation verschiedener Mitarbeiter erwerben Teilnehmer im Rahmen des Projekts zudem informell relevante Kompetenzen für einen praxisnahen Anwendungsfall.

In der Summe zeigt sich, dass zwar verschiedene ML-Weiterbildungsmöglichkeiten in der Forschungslandschaft vorliegen, diese aber vorrangig arbeitsverbunden stattfinden. Dabei wird vor allem auf das Konzept der Lernfabrik gesetzt. Lerner bekommen beim Wissenstransfer in ihren Arbeitsalltag jedoch keine Unterstützung.

2.2.5.3 Ergebnisse der Internetrecherche

Im Zusammenhang der Internetrecherche erfolgt eine Analyse von 117 Bildungsanbietern (Zukunftszentren, Netzwerk Mittelstand-Digital Initiative, Industrie- und Handelskammern, Lernfabriken, Plattform Lernende Systeme, Fraunhofer Institute, u.v.m.). Dabei können nach Durchführung mehrerer Exklusionsschritte final 92 Angebote identifiziert werden, welche mit den Begriffen künstliche Intelligenz, maschinelles Lernen, Data Science oder Data Analytics überschrieben sind. Diese Ansätze werden daraufhin hinsichtlich Format (virtuell, Präsenz, hybrid), Präsenzzort (insofern das Format in Präsenz ist)

und Einordnung in das arbeitsbasierte Lernen (siehe Abschnitt 2.2.2) näher untersucht.⁸ (Haselberger 2023)

Es fällt zunächst auf, dass 47% der Angebote in virtuellem Format angeboten werden. Hingegen finden 52% (absolut: 39 Weiterbildungen) in Präsenz statt. Zudem wird eines der untersuchten Angebote hybrid durchgeführt. Von den 39 Präsenzangeboten lassen sich acht im Unternehmen umsetzen, 19 in einer Lernfabrik und zwölf vollständig außerhalb der Arbeitsorganisation. Letztere Formate sind folglich durch fehlenden Praxisbezug charakterisiert. Sieben der acht analysierten unternehmensinternen Vorhaben stellen In-House-Schulungen dar. Sie sehen vor, dass die Weiterbildungen primär in zentralen Räumlichkeiten der Unternehmen und nicht in Produktionsnähe und somit dem Arbeitsort der Teilnehmer stattfinden. Das letzte der acht Vorhaben eignet sich insbesondere für Arbeitsstationen, welche realen Arbeitsplätzen nachempfunden sind. In der Analyse wurde darüber hinaus eine Einordnung in die Abstufungen des arbeitsbasierten Lernens vorgenommen. Es ist zu erkennen, dass 91 der 92 Angebote für das arbeitsorientierte Lernen exemplarisch in formalen Einrichtungen bei Bildungsanbietern oder in Räumlichkeiten von Universitäten stattfinden. Hingegen eignet sich lediglich ein Ansatz für das arbeitsverbundene Lernen. Keine Weiterbildung hingegen ist auf das arbeitsintegrierte Lernen ausgelegt (siehe Abbildung 11).




Abbildung 11: Verteilung der untersuchten Weiterbildungen nach Arbeitsplatznähe, eigene Darstellung in Anlehnung an Rosemeyer und Haselberger (2025)

2.2.6 Zwischenfazit zu den Grundlagen betrieblicher Weiterbildung

Für produzierende Unternehmen bietet das Lernen ihrer Mitarbeiter in Form von arbeitsintegriertem Lernen zahlreiche Vorteile. Stärker als die anderen erörterten Formen des

⁸ Für eine detaillierte Auflistung des Analyseverfahrens siehe Anhang A2 sowie Rosemeyer und Haselberger (2025).

arbeitsbasierten Lernens unterstützt es den Transfer und die Anwendung von in Schulungen erlerntem disziplinärem Wissen in den Arbeitskontext. Zudem erhöht es die Motivation der Mitarbeiter und verbessert das Arbeitsklima. Letztlich orientiert es sich an Unternehmenszielen und unterstützt deren Erreichung. In der praktischen Umsetzung sollte es dabei durch Methoden zum informellen und non-formalen Lernen unterstützt werden. Für die in Abschnitt 2.1.3 erarbeitete Zielgruppe der Prozessverantwortlichen und Teamleiter lassen sich eine Vielzahl von ML-Kompetenzen sowie Weiterbildungen identifizieren. Die durchgeführten Analysen (Abschnitt 2.2.5) zeigen jedoch auf, dass diese vorrangig auf das arbeitsorientierte und das arbeitsverbundene Lernen abzielen. So finden sie vor allem an dedizierten Lernorten wie Lernfabriken statt. Die Potenziale von arbeitsintegriertem Lernen werden hingegen nicht ausgenutzt. Es lässt sich weiterhin festhalten, dass die zuvor durchgeführten Recherchen jene Erkenntnisse hinsichtlich ML-Weiterbildungen von André et al. (2021b) nicht bestätigen können. Aus dieser Lücke kann der folgende Forschungsbedarf abgeleitet werden:

Forschungsbedarf 2: Entwicklung einer Weiterbildung, welche das arbeitsintegrierte Lernen für ML-Anwendungen fokussiert.

Um final darlegen zu können, ob mittels dieser Weiterbildung zudem ein Mehrwert generiert wird und damit die erarbeiteten Kompetenzen erreicht werden, bedarf es darüber hinaus einer quantitativen Überprüfung. Daraus lässt sich zudem folgender Forschungsbedarf ableiten:

Forschungsbedarf 3: Quantitative Überprüfung des erreichten Mehrwerts durch die entwickelte Weiterbildung.

2.3 Digitale Assistenzsysteme für die Produktion

In diesem Abschnitt wird der Begriff der digitalen Assistenz eingeführt. Dazu werden zunächst verschiedene Kategorisierungen vorgestellt (Abschnitt 2.3.1). Ein Schwerpunkt wird dabei auf solche Assistenzsysteme gelegt, welche sich zur Wissensvermittlung eignen (Abschnitt 2.3.2). Im Anschluss werden Ansätze zur Entwicklung digitaler Assistenzsysteme präsentiert (Abschnitt 2.3.3). Der darauffolgende Abschnitt 2.3.4 beleuchtet den Forschungsstand hinsichtlich Assistenzsystemen für ML-Anwendungen. Letztlich wird ein Zwischenfazit gezogen und Forschungsbedarfe abgeleitet (Abschnitt 2.3.5).

2.3.1 Definition und Begriffsabgrenzung

Da für Assistenzsysteme im Allgemeinen keine universelle Definition existiert (Braun 2018), werden im Folgenden verschiedene Ansätze mit diversen Kategorisierungen vorgestellt.

Gemeinhin stellen Assistenzsysteme technische Systeme dar, welche Menschen bei der Ausführung von Tätigkeiten unterstützen und es ihnen dadurch ermöglicht, sich verstärkt

auf andere Tätigkeiten zu konzentrieren (Schlund 2023). Damit ein System als Assistenzsystem bezeichnet werden kann, sind durch dieses vier Voraussetzungen zu erfüllen (Weidner 2015):

- Es unterstützt Menschen bei dessen Tätigkeiten, ohne sie ganz oder teilweise zu substituieren.
- Es belässt die Hoheit über die Ausführung von Aufgaben bei den Nutzern.
- Benutzer fungieren als Systembediener.
- Von dem System geht keine Gefahr für den Bediener oder für Dritte aus.

Zahlreiche Autoren sind sich darin einig, dass Assistenzsysteme für die Industrie in sensorielle, kognitive und physische Assistenzsysteme unterteilt werden können (Mark et al. 2021; Romero et al. 2016; Apt et al. 2018a). Doch während Apt et al. (2018a) die genannte Unterteilung ausschließlich für den Oberbegriff *digitale Assistenzsysteme* (DAS) führen, verstehen Mark et al. (2021) und Romero et al. (2016) die vorliegende Einordnung für Assistenzsysteme im Allgemeinen. Dieser Ansicht schließen sich Keller et al. (2019) und Schlund (2023) an, die die physische Assistenz aus der digitalen Assistenz herausnehmen. Die vorliegende Arbeit folgt der Einteilung letzterer Autoren. Da physische Assistenzsysteme keinen Fokus der weiteren Ausarbeitung darstellen, werden sie zudem von den folgenden Beschreibungen ausgeschlossen.

Apt et al. (2018a) beschreiben digitale Assistenzsysteme konkretisierend entlang der Charakteristika Art, Grad und Zielsetzung (siehe Abbildung 12). Auf diese wird im Folgenden näher eingegangen.




Abbildung 12: Charakteristika digitaler Assistenzsysteme, eigene Darstellung in Anlehnung an Apt et al. (2018a)

Gemäß den Autoren können DAS zunächst entlang des *Grads an Unterstützung* unterschieden werden. Sie sehen DAS mit niedrigem Grad als solche, die lediglich reine Handlungsanweisungen für einfache Arbeitssituationen bieten. Systeme mit mittlerer Unterstützung erlauben eine Unterstützung bei regelbasierten Entscheidungen mittlerer Komplexität und geben zudem Empfehlungen an Nutzer. Hingegen erlauben Systeme mit hoher Unterstützung Hilfe bei regelbasierten Entscheidungen hoher Komplexität oder

expertisebasierten Entscheidungen und kommunizieren bei diesen Empfehlungen an Nutzer. Letztlich können DAS auch variabel unterstützen. In diesem Fall sind sie modular aufgebaut und treffen Entscheidungen unterschiedlicher Komplexität und können gegebenenfalls kognitive Tätigkeitsbestandteile übernehmen.

Weiterhin kann eine Unterscheidung der *Art der Unterstützung* vorgenommen werden.

Sensorielle Assistenzsysteme dienen zur Erweiterung der Sinnesorgane und unterstützen dabei vor allem hör- und sehbedingt (Apt et al. 2018a). Sie umfassen darüber hinaus die Ermittlung von Positions-, Umgebungs- und Zustandsinformationen (Schlund 2023). In Produktionsumgebungen können sensorielle Assistenzsysteme bei der Erfassung von Signalen Hilfe leisten, die für den Bediener nur schwer zugänglich sind (Romero et al. 2016). Mittels sensorieller Assistenzsysteme lassen sich folglich die Dokumentation über Produktionszustände vereinfachen, Maschinen leichter überwachen und Prozessfortschritte schneller ermitteln (Keller et al. 2019). Umgesetzt sind sensorische Assistenzsysteme zum Beispiel in Form von Warnleuchten oder akustischen Signalen (Mark et al. 2021).

Kognitive Assistenzsysteme (KAS) hingegen helfen Nutzern bei der Informationsverarbeitung (Aufnahme, Verarbeitung und Bereitstellung) (Merkel et al. 2018) sowie bei der Ausführung ihrer Arbeit (Mark et al. 2021) und unterstützen sie in der Folge bei der Entscheidungsfindung (Apt et al. 2018a). KAS dienen somit vor allem zur psychischen Entlastung der Beschäftigten (Bovenschulte 2020). In realen Umgebungen lassen sich KAS exemplarisch mittels Smartphones, Virtual Reality, Augmented Reality, Tablets oder Wearables umsetzen (Mark et al. 2021). Ist ein KAS eine reine Softwarelösung, so wird die Ausführung der Tätigkeiten auf Basis von Eingaben per Tastatur oder Sprache erfasst (Bovenschulte 2020). Apt et al. (2018b) unterscheiden KAS darüber hinaus gemäß ihrem Aufgabenumfang:

- *Hilfssysteme* stellen bestehendes analoges Wissen in digitaler Form bereit und geben Arbeitsanweisungen.
- *Adaptive Assistenzsysteme* ermöglichen eine sensorische Erfassung von Arbeitsvorgängen, des umgebenden Kontexts, oder des Nutzers und lassen sich von diesem individuell anpassen.
- *Tutorielle Assistenzsysteme*, respektive *Tutorialsysteme*⁹, sind adaptive Assistenzsysteme, die das Lernen im Prozess der Arbeit unterstützen (sogenannte Lernzeuge). Sie ermöglichen somit die Vermittlung von situativem und arbeitsrelevantem Wissen. Da den tutoriellen Assistenzsystemen (TAS) im Zusammenhang dieser Arbeit eine hohe Relevanz zukommt, werden diese in Abschnitt 2.3.2 näher charakterisiert.

⁹ Die beiden Begriffe werden in der Folge synonym verwendet.

Letztlich lässt sich die *Zielstellung* von DAS unterscheiden. Übernehmen Assistenzsysteme kompensatorische Aufgaben, so dient dies beispielsweise dem Ziel, individuelle auf die Tätigkeit bezogene Defizite aufgrund von Alter, Behinderung oder ethnischer Herkunft beziehungsweise Nationalität zu kompensieren (Apt et al. 2018a). Ein besonderer Fokus liegt dabei auf dem Ausgleich von Körper- und Sinnesbehinderungen (Engels 2016). Assistenzsysteme, welche einen erhaltenden Charakter haben, kommen insbesondere in der Pflege zum Einsatz und haben dort das Ziel, die Arbeitskraft und Leistungsfähigkeit von Angestellten zu wahren (Apt et al. 2018a). Neben physischen Systemen kommen DAS beispielsweise zur Sturz- oder Notfallerkennung, Ortung oder Orientierung zum Einsatz (Weiß 2017). Letztlich können DAS dazu beitragen, Ungleichgewichte zwischen gestellten Anforderungen und Qualifikationsprofilen von Mitarbeitern zu reduzieren – insbesondere dann, wenn zu erwarten ist, dass diese ohne Assistenzsysteme von neuen Aufgaben überfordert werden. Fähigkeitserweiternde Assistenzsysteme eignen sich insofern vor allem für temporäre Ansätze, wie Lernphasen im Zuge von Trainings und Einarbeitung. Entsprechende Assistenzarten sind daher in erster Linie kognitive und in besonderem Maße tutorielle Assistenzsysteme. (Apt et al. 2018a)

2.3.2 Tutorielsysteme zur Lernunterstützung

Wie bereits im vorherigen Kapitel erläutert, eignen sich KAS, und hier insbesondere Tutorielsysteme, für das arbeitsbasierte Lernen. Während Hilfssysteme bereits gegenwärtig in zahlreichen Produktionsumgebungen zu finden sind, befinden sich TAS noch im Anfangsstadium und sind im realen Betrieb kaum verbreitet. Sie bieten aber das Potenzial, als informelle Weiterbildungswerkzeuge genutzt zu werden und das Lernen im Prozess der Arbeit zu ermöglichen. (Apt et al. 2018b) Individuelle Kompetenzprofile können in der Folge leichter erreicht werden als mit herkömmlichen Weiterbildungen (Apt et al. 2016). Einen besonderen Mehrwert bieten TAS in der Kombination mit Gruppenarbeiten (Apt et al. 2018a). Mit Hinblick auf die Zielstellung dieser Arbeit wird für das bessere Verständnis eine Vertiefung der Charakteristika von Tutorielsystemen vorgenommen und erläutert, wie sich TAS zur Wissensvermittlung eignen.

Erste Ansätze in der Entwicklung lassen sich bis in die 1970er Jahre zurückdatieren. In ihrer Ausarbeitung beschreiben Hartley und Sleeman (1973) Gestaltungsprinzipien für TAS. So fordern sie unter anderem die Repräsentation der Lehraufgabe, eine Repräsentation des Lerners und eine Menge an didaktischen Methoden zur Wissensvermittlung. Heutige Ansätze haben zum Ziel, Intelligenz in die TAS zu bringen und somit Inhalte individuell zur Verfügung zu stellen. Solche Lösungen werden als intelligente tutorielle Systeme (ITS) bezeichnet. Ein ITS ist ein computergestütztes Lehrsystem, das Techniken der künstlichen Intelligenz einsetzt, um das in einem bestimmten Feld erforderliche Wissen zu präsentieren (Hsieh und Hsieh 2001). Exemplarische Ansätze finden sich bei Huang et al. (2021) oder Hodaie et al. (2018).

TAS stellen ihren Nutzern den richtigen Inhalt zur richtigen Zeit zur Verfügung und unterstützen sie während eines Lernprozesses (Rodrigues et al. 2005). Dabei bieten sie

neben Fragen und Schritten zur Erzielung der avisierten Aufgabe beispielsweise Möglichkeiten zum Einbezug weiterführender Informationen, wie Texte, Bilder oder Videos, Feedback zu vorgenommenen Handlungen sowie Funktionen zur Wissensrecherche und -dokumentation (Apt et al. 2018a). Dazu greifen TAS auf diverse stationäre und mobile Endgeräte zurück, wobei der Schwerpunkt auf mobilen Geräten liegt (Apt et al. 2018a; Mehler et al. 2021). Vor dem Hintergrund obenstehender Erläuterungen lassen sich in Anlehnung an Apt et al. (2018b) TAS wie folgt zusammenfassend definieren:

Definition Tutorialsystem:

Ein kognitives Assistenzsystem, das das Lernen im Prozess der Arbeit unterstützt. Es ermöglicht dazu die Vermittlung von situativem und arbeitsrelevantem Wissen.

Von zentraler Relevanz bleibt die Übertragung von Kenntnissen, Fähigkeiten und Wirkungsweisen eines menschlichen Experten auf das Assistenzsystem (Rodrigues et al. 2005). So muss relevantes Wissen derart inkludiert werden, dass es für Lerner mit Hinblick auf ihr Wissensniveau passend ist. Gleichmaßen müssen Lernaufgabe und Technologie auf einander abgestimmt sein, um Überforderung seitens der Nutzer zu verhindern (Task-Technology-Fit) (Mehler et al. 2021). Letztlich gilt es, das Assistenzsystem selbst lernförderlich zu gestalten (Terhoeven et al. 2019; Apt et al. 2018a). Entwickler müssen diesbezüglich entscheiden, ob das Design darauf ausgerichtet sein soll, Lernprozesse zu unterstützen oder ob es die Leistung der Nutzer bei gleichbleibendem Kompetenzniveau erhöhen soll (Apt et al. 2018a). Dazu ist es notwendig, Entwickler diverser Disziplinen einzubeziehen, wie beispielsweise der Didaktik, der Mensch-Computer-Interaktion und der Softwaretechnik (Nkambou et al. 2010). In der Summe bieten TAS den Mehrwert, dass sich durch ihren Einsatz Lern- und Arbeitsaufgaben immer ähnlicher werden (Vladova und Gronau 2022). Insbesondere in der Kombination mit non-formalem Lernen können TAS ihr volles Potenzial entfalten (Blumberg und Kauffeld 2021).

2.3.3 Entwicklung digitaler Assistenzsysteme

Zur Entwicklung digitaler Assistenzsysteme liegen in der Literatur diverse Vorgehensmodelle, Leitfragen und Architekturen vor. In diesem Abschnitt werden drei Modelle vorgestellt, welche die Entwicklung von DAS unterstützen. Sie lassen sich zudem auf die Entwicklung von TAS übertragen.

Architektur nach Mir und Quadri

Mir und Quadri (2009) entwickeln eine Architektur bestehend aus den drei Teilsystemen Datenbankmanagement, Wissensmanagement und der Benutzeroberfläche (siehe Abbildung 13). Das erste Teilsystem speichert und verwaltet zu integrierende Daten und ermöglicht den Zugriff auf diese mit Hilfe eines Datenbankmanagementsystems. Das Wissensmanagementsystem repräsentiert die Kernaufgabe des DAS und führt die wesentlichen Schritte aus. Letzteres Teilsystem dient als Schnittstelle zu dem Benutzer. Hierzu greift das DAS auf Eingabe- und Ausgabegeräte zurück.




Abbildung 13: Architektur digitaler Assistenzsysteme, eigene Darstellung in Anlehnung an Mir und Quadri (2009)

Menschzentrierte Entwicklungsansätze

In seiner Arbeit untersucht Hambach (2019) Vorgehensmodelle für die Entwicklung von DAS und extrahiert final, dass sich für Assistenzsysteme insbesondere solche mit *menschzentriertem Ansatz* (im Folgenden als HCD abgekürzt¹⁰) eignen. Zu diesem Schluss kommen auch weitere Autoren (Nelles et al. 2016; Apt et al. 2018b; Pacaux-Lemoine et al. 2017). Bemerkenswert ist jedoch, dass nur wenige Autoren tatsächlich auf menschzentrierte Gestaltungsansätze setzen (Grandi et al. 2020; Rosemeyer und Metternich 2024). Mit Hinblick auf seine Relevanz, wird im Folgenden ein Prozess zur menschzentrierten Gestaltung sowie notwendige Anforderungen näher beleuchtet.

Ein weit verbreitetes Verfahren zur Gewährleistung von HCD im Zusammenhang der Entwicklungsschritte (Hoerner et al. 2023) wird in der DIN EN ISO 9241-210 vorgestellt (Deutsches Institut für Normung 2019a)¹¹ (siehe Abbildung 14). Hierbei gilt es für Entwickler zu Beginn, den gesamten Entwicklungsprozess eines DAS zu planen. Dazu stehen drei Prinzipien jedem Designprozess vor (Apt et al. 2018b):

- 1) Es erfolgt eine aktive Beteiligung der zukünftigen Nutzer. Dies hat zum Ziel, ein klares Verständnis über Anforderungen zu erhalten.
- 2) Gestaltungslösungen werden iterativ entwickelt, um eine kontinuierliche Annäherung an die späteren Nutzer und deren Anforderungen zu erreichen.
- 3) Das Entwicklerteam ist interdisziplinär aufgestellt und kann somit verschiedene Anforderungen abbilden.

¹⁰ Vom englischen Begriff Human-centered Design

¹¹ Insofern nicht anderweitig gekennzeichnet, sind die folgenden Beschreibung an der angegebenen Norm orientiert.




Abbildung 14: Entwicklung menschzentrierter Systeme, eigene Darstellung in Anlehnung an Deutsches Institut für Normung (2019a)

Im ersten Schritt des Vorgehens wird ein Fokus auf den aktuellen oder den für die Gestaltung vorgesehenen *Nutzungskontext* gelegt. Es gilt, Benutzermerkmale, Aufgaben sowie die organisatorische, technische und physische Umgebung zu analysieren und zu bewerten. Dies umfasst neben den eigentlichen Nutzern auch weitere tangierte Personengruppen sowie deren Ziele und Aufgaben.

Im Kontext der darauffolgenden *Nutzungsanforderungen* soll nicht nur ein Fokus auf die funktionalen Anforderungen eines Systems gelegt werden, sondern es muss auch eine Darstellung von Anforderungen im Zusammenhang mit dem Nutzungskontext vorgenommen werden. Dies umfasst beispielsweise ergonomische Aspekte, Gebrauchstauglichkeitsanforderungen und -ziele sowie organisatorische Anforderungen.

Sind die Anforderungen umfangreich spezifiziert und erhoben, werden im dritten Schritt *Gestaltungslösungen* erarbeitet. Hierbei sind insbesondere die Nutzeraufgaben zu konkretisieren, die Benutzer-System-Interaktion und die Benutzungsschnittstelle zu gestalten. Um das zu bewerkstelligen, sind die *Interaktionsprinzipien* der DIN EN ISO 9241-110 (Deutsches Institut für Normung 2020) zu berücksichtigen. Die Norm fordert, dass in menschzentriert gestalteten Systemen folgende Kriterien umfasst sind:

- *Aufgabenangemessenheit*: Ein DAS basiert auf den charakteristischen Eigenschaften der definierten Aufgabe und unterstützt somit die Nutzer bei der Erledigung ihrer Aufgaben.
- *Selbstbeschreibungsfähigkeit*: Ein DAS bietet angemessene Informationen an, die den Nutzern die Möglichkeiten des Systems leicht verständlich zugänglich machen.
- *Erwartungskonformität*: Das Verhalten des DAS ist auf Grundlage des Nutzungskontexts und anerkannten Konventionen vorhersehbar.
- *Erlernbarkeit*: Ein DAS unterstützt Nutzer bei der Entdeckung der Fähigkeiten des Systems mittels Exploration, minimalem Lernaufwand und liefert diesen Lernansätze, insofern Lernen notwendig ist.

- *Steuerbarkeit*: Ein DAS erlaubt den Nutzern die vollständige Kontrolle über die grafische Benutzeroberfläche (GUI¹²), inklusive Geschwindigkeit, Abfolge und Individualisierung der Interaktion.
- *Robustheit gegen Benutzerfehler*: Ein DAS liefert Ansätze, sodass Fehler je nach Möglichkeit entweder verhindert oder toleriert werden und unterstützt Nutzer bei der Fehlerbehebung.
- *Benutzerbindung*: Ein DAS stellt seine Funktionen und inkludierte Informationen auf einladende und motivierende Art dar und fördert somit eine kontinuierliche Interaktion zwischen Nutzern und System.

Im vierten und letzten Schritt erfolgt eine *Evaluation* der Lösungen aus Nutzerperspektive. Somit lassen sich beispielsweise Stärken und Schwächen der Lösungen ermitteln. Auch kann in der Folge die Erfüllung der Nutzeranforderungen beurteilt werden. Insofern relevant, können weiterhin Vergleiche zwischen verschiedenen Gestaltungsalternativen gezogen werden. Letztlich lassen sich potenzielle weiterführende Informationen über Nutzererfordernisse sammeln.

Erfolgt eine Orientierung an den Schritten aus der Teilnorm -210 und eine Betrachtung der zuvor beschriebenen Interaktionsprinzipien, so fördert dies die Erreichung einer hohen Gebrauchstauglichkeit¹³ (Mehler et al. 2021). Einen Hebel dazu stellen die drei Grundprinzipien *Effektivität*, *Effizienz* und *Zufriedenheit* dar, welche in der DIN EN ISO 9241-11 (Deutsches Institut für Normung 2018a) vorgestellt werden. Demzufolge beschreibt die Effektivität die Genauigkeit und Vollständigkeit, mit denen Nutzer definierte Ziele erreichen und bezeichnet damit das Ausmaß der Übereinstimmung zwischen tatsächlichem und angestrebtem Ergebnis. Hingegen stellt die Effizienz das Verhältnis von erreichten Ergebnissen zu eingesetzten Ressourcen (Zeit, Personal, Budget, Materialien) dar. Die Zufriedenheit letztlich umfasst das Ausmaß, in dem physische, kognitive und emotionale Reaktionen von Nutzern, welche aus der Benutzung eines DAS resultieren, mit den Erfordernissen und Erwartungen übereinstimmen. Zu beachten ist, dass Nutzer von DAS unabhängig ihrer Zufriedenheit effizient in der Bearbeitung oder unabhängig von ihrer Effizienz zufrieden sein können. (Deutsches Institut für Normung 2018a)

Handlungsfelder nach Apt et al.

In ihrer Arbeit präsentieren Apt et al. (2018b) drei Handlungsfelder, welche bei der Entwicklung von Tutorialsystemen betrachtet werden müssen (siehe Abbildung 15).

¹² Vom englischen Begriff Graphical User Interface

¹³ Der englische Begriff Usability ist im Sprachgebrauch die vermutlich gebräuchlichere Formulierung.




Abbildung 15: Handlungsfelder bei der Entwicklung digitaler Assistenzsysteme, eigene Darstellung in Anlehnung an Apt et al. (2018b)

Sie zielen dabei erstens auf die *Ergonomie* ab. Da sich diese an den Inhalten der DIN EN ISO 9241 orientiert, wird auf die Ergonomie nicht vertiefend eingegangen. Das zweite übergeordnete Handlungsfeld ist die *Didaktik*. So sind verschiedene didaktische Methoden zu integrieren (siehe Abbildung 16). Hierbei lassen sich die Exposition, das kooperative beziehungsweise das kollaborative Lernen, das problembasierte Lernen sowie das forschungsbasierte Lernen, respektive das arbeitsplatzbasierte Lernen, unterscheiden. Die Exposition hat zum Ziel, Theorieinhalte strukturiert unter Verwendung verschiedener Medien den Lernern darzustellen und dient dem Zweck, Faktenwissen zu vermitteln. Lernen erfolgt dabei individuell. In Abgrenzung dazu bieten das kooperative beziehungsweise kollaborative Lernen den Mehrwert, dass Kompetenzen in der Zusammenarbeit mit Lernpartnern entstehen. Kooperatives Lernen ist dabei dadurch gekennzeichnet, dass deklaratives Wissen zunächst individuell erworben und im Anschluss in Gruppen diskutiert, erläutert und vertieft wird (Aronson und Patnoe 1997). Beim kollaborativen Lernen hingegen entsteht Wissen vollständig in einer Gruppe (Dillenbourg 1999). Als dritte und vierte didaktische Methode stellen Apt et al. (2018b) das problembasierte sowie das forschungs- und arbeitsplatzbasierte Lernen auf. Das problembasierte Lernen hat zum Ziel, die Problemlösungsfähigkeit zu stärken. Es bietet den Mehrwert, dass irrelevante Lerninhalte leichter gefiltert und verschiedene Disziplinen besser kombiniert werden können. (Schmidt 1983) Lernen geschieht dabei in kleinen Lerngruppen, in denen Probleme Mittelpunkt und Anreiz für das Lernen darstellen. Neue Informationen werden selbstständig akquiriert. (Barrows 1996)




Abbildung 16: Methoden im Handlungsfeld Didaktik, eigene Darstellung in Anlehnung an Apt et al. (2018b)

Von den didaktischen Methoden grenzen Apt et al. sogenannte *Lernmotivationale Aspekte* ab. In diese fallen nach Ansicht der Autoren das spielerische Lernen sowie das selbstbestimmte, beziehungsweise das selbstregulierte Lernen. Lerner sind dabei in der Verantwortung, Lernziele, -thema, -tempo, -inhalte sowie die Lernumgebung selbst zu bestimmen. Bei der Integration spielerischer Elemente lassen sich die beiden Ansätze Serious Games und Gamification unterscheiden. Serious Games sind strukturierte

Spielsituationen, die das Lernen erleichtern sollen. (Abele et al. 2024). Bei der Gamification werden Elemente des Spieldesigns in nicht-spielerische Kontexte integriert. Sie zielt darauf ab, reale Situationen motivierender, unterhaltsamer und ansprechender zu gestalten. (Deterding et al. 2011; Abele et al. 2024)

Als drittes Handlungsfeld sehen Apt et al. (2018b) die *Wahl des Mediums*, respektive der *Technologie*. Dieses ist abhängig von den Lernzielen, der Lernumgebung und den Lerninhalten. Weiterhin ist zu überlegen, ob Lernen mobil möglich sein soll oder ortsgebunden stattfindet. Zudem ist die Umgebung hinsichtlich Lärm- oder Lichtbelastung zu bewerten. Verschiedene Ansätze wie Computer, Tablets oder Augmented Reality wurden bereits in Abschnitt 2.3.1 vorgestellt.

2.3.4 Tutorielle Assistenzsysteme zur Unterstützung von ML-Projekten

In diesem Abschnitt werden publizierte Assistenzsysteme aus der Forschung näher beleuchtet. Es soll somit geklärt werden, ob bestehende Lösungen den aufgedeckten Bedarf nach TAS für das arbeitsintegrierte Lernen zu ML-Anwendungen in der Produktion bereits umfassend decken. Zur Zielerreichung führt der Autor dieser Arbeit in Rosemeyer et al. (2024b) eine systematische Literaturrecherche durch. Aufgrund des Neuheitscharakters von TAS und der damit verbundenen geringen Trefferanzahl wird in der Recherche auf die Oberkategorie, kognitive Assistenzsysteme, zurückgegriffen. Die Autoren identifizieren in der Summe 29 KAS, welche daraufhin näher analysiert werden. Dabei beleuchten sie in Anlehnung an ein in der Literatur vorgeschlagenes Modell verschiedene inhaltliche und konzeptionelle Kriterien (siehe Abbildung 17). So wird beispielsweise der Einbezug der Nutzer in Entwicklungsschritte und die Evaluation betrachtet. Weiterhin wird die Anwendung der Systeme in der Praxis bewertet. Auch wird ein Fokus auf die Adressierung der Anforderungen von KMU gelegt. Dies umfasst, wie beschrieben, die Konzeptionierung einer Netzwerkinfrastruktur sowie die Generierung von und den Zugriff auf relevante Produktionsdaten. Letztlich erfolgt eine Fokussierung auf die Anwendbarkeit im Zuge des arbeitsintegrierten Lernens. Hierbei ist es von Relevanz, dass Lösungen Maßnahmen für das non-formale und das informelle Lernen enthalten. Ausgewählte Lösungen, welche für diese Arbeit als insbesondere relevant eingestuft wurden, werden in der Folge vorgestellt und dabei die Umsetzung obenstehender Kriterien beleuchtet.




Abbildung 17: Untersuchungsrahmen der systematischen Literaturrecherche, eigene Darstellung in Anlehnung an Rosemeyer et al. (2024b)

Neunzig et al. (2023b) entwickeln mit ihrem Assistenzsystem MLpro einen niederschweligen Ansatz zur Generierung von ML-Algorithmen im Zuge der prädiktiven Qualitätssicherung. Dazu nehmen sie Anforderungen in Bezug auf die technische Gestaltung auf, betrachten die Nutzbarkeit seitens der Anwender allerdings nicht. Hingegen stufen sie Nutzer in die drei Kompetenzniveaus Beginner, Fortgeschrittener und Experte ein. Abhängig einer anfänglichen Selbsteinschätzung unterscheiden sich je nach Niveau die Freiheitsgrade im Kontext der ML-Algorithmik und des Umfangs an Funktionserklärungen. Die finale Anwendung erfolgt auf einem öffentlichen Datensatz. Eine Betrachtung der Netzwerkinfrastruktur und der Datenquellen erfolgt nicht. Es wird lediglich dargelegt, dass diese einbezogen werden.

Villanueva Zacarias et al. (2018) konzipieren eine Lösung, welche sich mit unterschiedlichen Personengruppen auseinandersetzt. Dazu erheben sie eingangs Anforderungen aus der Domänenperspektive, der Netzwerkinfrastruktursicht und ML-Aspekten. Diese überführen sie in ein Framework und beschreiben dieses daraufhin umfassend. Auffällig ist der interdisziplinäre Ansatz, bei dem verschiedene Stakeholder Berücksichtigung finden. Im Kontext einzelner Subsysteme wird dann ein Fokus auf die Datengenerierung und Netzwerkinfrastruktur gelegt. Hingegen wird nicht ersichtlich, inwiefern das System sich zur Kompetenzentwicklung eignet, da keine entsprechenden Maßnahmen beschrieben sind. Die finale Evaluation erfolgt durch die Autoren selbst.

Senna et al. (2020) haben mit ihrer Lösung zum Ziel, eine Stärkung der kognitiven Fähigkeiten der Nutzer ihres Systems im Hinblick auf einen intelligenteren und komplexeren Entscheidungsprozess zu ermöglichen. Sie legen dazu einen Fokus auf die Mensch-Maschine-Interaktion ihrer Lösung, welche allerdings final nicht bewertet wird und damit die Zielerreichung nicht sichergestellt ist. Folglich lässt sich nicht darlegen, ob Nutzer die beschriebene Stärkung tatsächlich erfahren und sich ihr Kompetenzniveau erhöht. Auch wird kein Fokus auf die Kriterien aus Sicht von KMU gelegt, da beispielsweise keine Erläuterung von inkludierten Daten erfolgt.

Der Lösungsansatz von Angulo et al. (2023) hat zum Ziel, die technische Arbeitsbelastung der Nutzer zu reduzieren und ML-Implementierungen zu vereinfachen. Dazu ermitteln sie arbeitswissenschaftliche Anforderungen aus Sicht von Nutzern und legen

darauflin dar, welche kognitive Unterstützung diese benötigen. Die Anforderungen überführen sie anschließend in ein kognitives Modul, welches Kernbestandteil ihres Assistenzsystems ist. Auszuführende Aufgaben im Zuge der Entwicklung von ML-Anwendungen werden durch dieses übernommen, sodass sich Nutzer auf ihre Aufgaben konzentrieren können. Obgleich arbeitswissenschaftliche Aspekte berücksichtigt sind, lassen sich keine didaktischen Prinzipien identifizieren, welche Grundlage für die Weiterbildung der Nutzer darstellen. Die Anwendung erfolgt final unter Betrachtung der Nutzererfahrungen.

Garouani et al. (2022) stellen einen konzeptionellen Ansatz und eine konsekutive Operationalisierung vor, die es industriellen Akteuren, welche nicht mit ML-Anwendungen vertraut sind, Algorithmen für ein gegebenes Problem auszuwählen und diese zu konfigurieren erlaubt. Dabei greifen sie auf AutoML und erklärbare künstliche Intelligenz zurück, damit die Nutzer die Ergebnisse zum einen auf einfache Art entwickeln und zum anderen leicht interpretieren können. Die Erklärungsansätze lassen sie im Anschluss durch Anwender bewerten. Während die ML-Pipeline zwischen Datenbewertung und Evaluation umfassend betrachtet wird, wird kein Fokus auf vorgelagerte Schritte gelegt. Die Anforderungen von KMU werden daher nur bedingt erfüllt.

Auf Grundlage der angeführten Analysen lassen sich abschließend vier Forschungslücken festhalten, welche zukünftig adressiert werden sollten (Rosemeyer et al. 2024b):

- Es wird nur wenig Fokus auf die Generierung von und den Zugriff auf relevante Produktionsdaten gelegt, welche eine essenzielle Grundlage von ML-Anwendungen darstellen.
- Nutzer werden nur geringfügig während der Entwicklung betrachtet. Selbiges gilt für die spätere Anwendung, welche oftmals von den Autoren der zitierten Publikationen selbst durchgeführt werden.
- Die Systeme eignen sich nur bedingt für den Einsatz im arbeitsintegrierten Lernen, da zumeist keine weiterführenden Erläuterungen über die Funktionsweise einzelner Schritte und Hintergrundinformationen dargelegt werden.
- Die Assistenzsysteme werden vorrangig in Laborumgebungen oder auf Basis von öffentlichen Datensätzen evaluiert. Es kann also keine Aussage darüber getroffen werden, inwiefern sich die Lösungen tatsächlich für Industrie Probleme eignen.

Aufbauend auf den identifizierten Lücken beschreiben die Autoren Anforderungen an zukünftige Lösungen:

- Es ist notwendig, dass relevante Stakeholder zukünftig in die Entwicklung und Evaluation eingebunden werden. Die Wahrscheinlichkeit für Akzeptanz aufseiten der Nutzer und die Nutzbarkeit durch selbige erhöht sich in der Folge.
- Zukünftige Entwicklungen sollten sich an den Bedürfnissen von KMU orientieren.
- Es sollten Hintergrundinformationen inkludiert werden, sodass Nutzer durch die Anwendung der Assistenzsysteme lernen können.

2.3.5 Zwischenfazit zu den Grundlagen digitaler Assistenzsysteme

TAS, welche als Unterstützung für das arbeitsintegrierte Lernen fungieren können, assistieren Nutzer bei der Vermittlung von situativem und arbeitsrelevantem Wissen und sind damit für Nutzer fähigkeitserweiternd. Bei deren Entwicklung sind unter anderem Bausteine der Didaktik, Ergonomie sowie Datenbankstrukturen und eine Benutzeroberfläche zu berücksichtigen. Zur strukturierten Entwicklung eignen sich zudem menschenzentrierte Gestaltungsprozesse, da diese die Anforderungen der späteren Nutzer bestmöglich umfassen. Hieraus lässt sich der folgende Forschungsbedarf ermitteln:

Forschungsbedarf 4: Identifikation der relevanten Inhalte für die Gestaltung eines entsprechenden TAS.

Auf Grundlage der Analyse aus Abschnitt 2.3.4 lässt sich zudem festhalten, dass bestehende TAS zwar wesentliche Schritte einer ML-Pipeline adressieren, relevante Aufgaben automatisieren und somit die Nutzung zur Laufzeit im Produktionsbetrieb abbilden. Kompetenzentwicklung und Lernaspekte werden allerdings nur sehr rudimentär umfasst. Sie fokussieren darüber hinaus technische Entwicklungen, lassen nutzerbezogene und menschenzentrierte Aspekte hingegen weitestgehend außen vor. In Summe decken die ermittelten Lösungen den anfangs beschriebenen Bedarf nach Tutorialsystemen für das arbeitsintegrierte Lernen für ML-Anwendungen nicht ausreichend ab, sodass weiterhin Notwendigkeit nach einem entsprechenden Gestaltungsansatz besteht. Entsprechend lässt sich weiterhin folgender Forschungsbedarf festhalten:

Forschungsbedarf 5: Formulierung allgemeingültiger Handlungsempfehlungen zur Gestaltung von Tutorialsystemen.

Um die Handlungsempfehlungen erfolgreich in der Praxis anwenden zu können, ist darüber hinaus die Unterstützung durch ein methodisches Vorgehen notwendig, welches Anwender der Empfehlungen mit operativen Leitlinien bei der praktischen Umsetzung anleitet:

Forschungsbedarf 6: Entwicklung eines strukturierten Vorgehens zur Anwendung der allgemeingültigen Handlungsempfehlungen.

2.4 Fazit zum Stand der Technik und Identifikation der Forschungslücke

Zur Erhöhung der Prozess- und Produktqualität produzierender Unternehmen bieten ML-Anwendungen große Potenziale. Werden sie strukturiert und unter Berücksichtigung sämtlicher Stakeholder im betrieblichen Umfeld eingeführt, eignen sie sich zur faktenbasierten Identifikation von abnormalen Vorkommnissen. Insbesondere in der Instandhaltung können ML-Lösungen durch Zustandsüberwachungen und -prognosen zu Kosteneinsparungen führen. Es zeigt sich aber, dass produzierende Unternehmen nur geringfügig von den Potenzialen von ML-Lösungen profitieren. Dies liegt vor allem an

einem Mangel an Kompetenzen hinsichtlich Projektierung und Nutzung in der Belegschaft. Hingegen bieten Citizen Data Scientists die Möglichkeit, bestehende Hürden zu adressieren und die Verbreitung von ML im Produktionskontext zu erhöhen. Da diese auf dem Arbeitsmarkt nur schwer zu finden sind, besteht für Unternehmen Bedarf, interne Mitarbeiter zu CDS weiterzubilden. Hierzu sind insbesondere Fach- und Führungskräfte in der Rolle von Prozessverantwortlichen und Teamleitern im unteren Management zu betrachten. Bestehende Qualifizierungsmaßnahmen eignen sich diesbezüglich jedoch nur bedingt, da sie vornehmlich auf das arbeitsorientierte und -verbundene Lernen setzen. Neben einem Mangel an Zeit für die Teilnahme besteht für die Zielgruppe bei bestehenden Schulungen ein Transferproblem, da sie erlernte Inhalte nur schwer auf das eigene Arbeitsfeld übertragen können. Während zwar Wissen zu ML-Lösungen in den Maßnahmen gewinnbringend aufgebaut werden kann, wird Handlungs- und Problemlösungsfähigkeit nur unzureichend sichergestellt. Dem entgegen steht das arbeitsintegrierte Lernen, bei dem Theorie und praktische Umsetzung unmittelbar problembezogen an einem unternehmensinternen Anwendungsfall erlernt werden können. Es unterstützt den Transfer und die Anwendung von disziplinärem Wissen in Arbeitssituationen und erlaubt selbstbestimmtes Lernen im Lerntempo der Lerner. Das vorhandene Potenzial von AiL wird von bestehenden Maßnahmen jedoch nicht erschöpfend ausgefüllt. Einen Ansatz, um AiL zu ermöglichen, stellen fähigkeitserweiternde Assistenzsysteme, und hier insbesondere Tutorielsysteme, dar. Diese bieten neben leitenden Fragen und Schritten zur Erzielung der avisierten Aufgabe die Möglichkeit zum Einbezug weiterführender notwendiger Informationen und unterstützen Lerner abhängig vom spezifischen Schritt variabel. Eine Analyse vorhandener Lösungen zeigt jedoch, dass sich Entwicklungen rund um Assistenzsysteme für ML-Anwendungen vornehmlich auf technische Aspekte konzentrieren und nur bedingt für das AiL geeignet sind. Sowohl Anforderungen der Nutzer als auch solche aus didaktischer Perspektive sind in diesen nur in geringem Maße umfasst.

Es lässt sich somit in Summe festhalten, dass vorhandene Ansätze in Literatur und Praxis den in den Abschnitten 1.1 und 1.2 ermittelten Bedarf an TAS zur Realisierung von ML-Anwendungen in der Fertigung nicht vollumfänglich decken und der Bedarf in der Folge weiterhin besteht. Zukünftige Tutorielsysteme sollten daher mit Fokus auf Nutzeranforderungen konzipiert werden sowie Möglichkeiten für das informelle und non-formale Lernen bieten. Nutzer können dabei problembasiert und durch unmittelbare Nähe zum Arbeitsplatz relevantes ML-Wissen beziehen und notwendige Handlungsfähigkeit erlangen (Zobel et al. 2018). Es gilt dabei, Anforderungen sowohl aus dem maschinellen Lernen, der betrieblichen Weiterbildung als auch von digitalen Assistenzsystemen zu erfüllen. In der Folge lassen sich fundierte Hinweise und Empfehlungen für die Gestaltung von lernförderlichen Arbeitsassistenzsystemen ableiten (Mehler et al. 2021).

3 ZIELSETZUNG UND FORSCHUNGSKONZEPTION

Aufbauend auf dem in Abschnitt 1.2 aus der Praxis hergeleiteten Forschungsziel und der in Abschnitt 2.4 beschriebenen Forschungslücke wird in diesem Kapitel die Zielsetzung der Arbeit detailliert (Abschnitt 3.1). Abschnitt 3.2 elaboriert darauffolgend die Forschungskonzeption und stellt die gewählten Methoden zur Erarbeitung der Zielsetzung vor. Abschnitt 3.3 ordnet den Untersuchungsbereich genauer ein.

3.1 Konkretisierung der Zielsetzung

Wie in den vorherigen Kapiteln dargestellt, verweisen zahlreiche Autoren auf die Potenziale von tutoriellen Assistenzsystemen zur Ermöglichung von arbeitsintegriertem Lernen (Mehler et al. 2021; Rauch et al. 2020; Romero et al. 2016; Apt et al. 2018a; Franken et al. 2022). Für diese These mangelt es gemäß Abschnitt 1.1 gegenwärtig jedoch noch an empirischer Evidenz.

Im Zusammenhang dieser Arbeit wird daher ein systematischer Gestaltungsansatz zur Entwicklung tutorieller Assistenzsysteme unter Berücksichtigung wissenschaftlicher Voraussetzungen erarbeitet. Prozessverantwortliche und Teamleiter aus Produktionsumgebungen mit diskreter Fertigung erhalten in der Folge eine fähigkeitserweiternde Unterstützung, durch welche sie sowohl theoretisches Wissen als auch praktische Handlungsfähigkeit bei der Durchführung von ML-Projekten erlangen können. Zur Gewährleistung des Aufbaus von implizitem Wissen ist der Gestaltungsansatz derart konzipiert, dass resultierende TAS arbeitsintegriert angewendet werden können. Lernen erfolgt dabei problembasiert, wobei Ansätze für das informelle als auch non-formale Lernen enthalten sind. In der Folge werden Angehörige der Zielgruppe zu CDS.

Um das Forschungsziel zu erreichen, werden in diesem Abschnitt drei Forschungsteilziele (FTZ) aufgestellt. Diese basieren auf den in Kapitel 2 erarbeiteten Forschungsbedarfen (FB) und leiten das weitere Vorgehen.

Abschnitt 2.3.5 leitete her, dass es einer konzeptionellen Gestaltung von TAS benötigt. Hierbei sind zunächst inhaltliche Anforderungen zu erarbeiten (FB 4). Diese bestehen gemäß Abschnitt 2.4 aus den drei Disziplinen maschinelles Lernen, betriebliche Weiterbildung und digitale Assistenzsysteme. Auf Grundlage der Anforderungen können dann allgemeingültige Handlungsempfehlungen zur Gestaltung abgegeben werden (FB 5). In der Forschungslandschaft haben sich zu diesem Zweck Gestaltungsmodelle etabliert. Entsprechend wird folgendes Teilziel definiert:

Forschungsteilziel 1: Entwicklung eines Gestaltungsmodells als konzeptionelle Grundlage von TAS.

Zur Überführung der allgemeingültigen Handlungsempfehlungen in eine in der industriellen Praxis anwendbare Lösung ist anschließend ein strukturiertes Vorgehen zu entwickeln (FB 6). Dieses unterstützt Nutzer bei der systematischen Anwendung des Gestaltungsmodells. Das Vorgehen resultiert final in einer Softwarearchitektur. Somit lautet das zweite Teilziel wie folgt:

Forschungsteilziel 2: Entwicklung einer Operationalisierungsmethode zur praktischen Anwendung des Gestaltungsmodells.

Letztlich bedarf es gemäß Abschnitten 2.1.5 und 2.2.6 einer arbeitsintegrierten Weiterbildung, durch die Prozessverantwortliche und Teamleiter in der Produktion zu CDS werden (FB 1 und FB 2). Hierzu soll ein auf Grundlage von FTZ 1 und FTZ 2 erarbeitetes TAS in die praktische Anwendung kommen. Im Anschluss bedarf es einer quantitativen Überprüfung, ob dieses effektiver als herkömmliche Ansätze ist (FB 3). Folglich ist ein Vergleich mit einem klassischen Weiterbildungsansatz notwendig. Somit lässt sich das dritte Teilziel definieren als

Forschungsteilziel 3: Bewertung des Mehrwerts eines operationalisierten TAS in der betrieblichen Praxis, insbesondere im Vergleich zu einer klassischen Weiterbildung.

3.2 Forschungskonzeption und gewählte Methoden

In diesem Abschnitt wird die Forschungskonzeption zur Realisierung der Forschungsteilziele erläutert. Sie beschreibt die strukturelle Vorgehensweise und gibt einen Überblick über die verwendeten Methoden. In der vorliegenden Arbeit wird auf das Forschungskonzept der DRM (Blessing und Chakrabarti 2009) zurückgegriffen (siehe Abschnitt 1.3). Es bietet einen Ansatz für die Gestaltungsforschung und eignet sich somit zur Systematisierung der avisierten Entwicklung. Die DRM besteht aus den vier Phasen *Forschungsziel*, *Deskriptive Studie I*, *Präskriptive Studie* und *Deskriptive Studie II*, welche im Folgenden beschrieben werden. Parallel dazu erfolgt eine Übertragung auf das Vorgehen innerhalb dieser Arbeit. Eine Zusammenfassung der Forschungskonzeption sowie die verwendeten Methoden finden sich in Tabelle 4.

Tabelle 4: Forschungsprozess der vorliegenden Arbeit, eigene Darstellung in Anlehnung an Blessing und Chakrabarti (2009)

Phase der DRM	Aufgabe	Verwendete Methoden	Ergebnisse
For- schungsziel	Klärung des For- schungsgegenstands	Literaturrecherche	Forschungsbedarf aus Praxisperspektive Initialer Forschungsbedarf Forschungsgliederung

Phase der DRM	Aufgabe	Verwendete Methoden	Ergebnisse
Deskriptive Studie I	Theoretische Betrachtung	Literaturrecherche	Literaturbasierte Ausgangslage
	Stand der Forschung	Systematische Literaturrecherche	Forschungslücke aus Theorie und Praxis Ausführliche Forschungsziele
Präskriptive Studie	Definition von Anforderungen	Literaturrecherche Fragebogenstudie	Anforderungen an die Lösungen Präsentation von Handlungsalternativen
	Lösungsentwicklung	Deduktion	Schematischer Aufbau und Komponenten des Gestaltungsmodells Ordnungsrahmen und Phasen der Operationalisierungsmethode
Deskriptive Studie II	Anwendung der Lösungen	Deduktion Fragebogenstudie	Unterstützungsevaluation
	Evaluation der Lösungsanwendung	Randomisierte Kontrollgruppenstudie	Anwendungsevaluation
		Fragebogenstudien Deskriptive Statistik	Erfolgsevaluation Implikationen für die Zukunft

Forschungsziel

Die erste Phase der DRM fokussiert sich auf die Entwicklung des Forschungsziels. Dies geschieht vor allem auf Grundlage der Literatur. (Blessing und Chakrabarti 2009) Auf Basis von Literaturrecherchen wurde in Abschnitt 1.2 das Forschungsziel erstmals beschrieben. Ziel der vorliegenden Arbeit ist die systematische Gestaltung von tutoriellen Assistenzsystemen, um das arbeitsintegrierte Lernen zu ML-Anwendungen in der Produktion zu ermöglichen. Der Forschungsbedarf resultiert dabei sowohl aus dem ermittelten Handlungsbedarf aus industrieller Perspektive als auch bestehenden Defiziten in der Literatur.

Deskriptive Studie I

In der zweiten Phase findet eine deskriptive Studie zur Untersuchung des Forschungsstands statt. In dieser werden mittels einer Literaturrecherche notwendige wissenschaftliche Grundlagen sowie ein übergeordnetes Verständnis über grundlegende Sachverhalte aufgebaut. Zudem erfolgt anhand einer systematischen Analyse bestehender Arbeiten eine Konkretisierung der Forschungslücke. (Blessing und Chakrabarti 2009) Mit Bezug auf diese Arbeit lässt sich festhalten, dass zwar bereits zahlreiche Weiterbildungsangebote zum Thema auf dem Markt vorliegen (Abschnitt 2.2.5) und zudem eine Vielzahl an TAS für das Arbeiten mit ML-Anwendungen in der Forschungslandschaft existieren (Abschnitt 2.3.4). Weder die bestehenden TAS noch die angebotenen Weiterbildungen eignen sich jedoch für das arbeitsintegrierte Lernen und können die vorherrschende

Transferlücke von Theorie zur Praxis daher nicht schließen. Die in Abschnitt 1.2 beschriebene Zielstellung wird dazu in Abschnitt 3.1 konkretisiert und erweitert. Auf Basis des anfänglichen Forschungsziels werden darüber hinaus drei Forschungsteilziele abgeleitet.

Präskriptive Studie

In der dritten Phase findet eine präskriptive Studie statt. In diesem Zusammenhang erfolgt die Entwicklung der eigentlichen Lösung. Relevant ist hier vor allem, dass ein bestehendes Konstrukt verbessert oder vereinfacht wird. (Blessing und Chakrabarti 2009) Die folgende Beschreibung legt dar, wie die ersten zwei FTZ methodisch erreicht werden.

Zur theoretischen Beschreibung relevanter Aspekte des TAS wird im ersten Schritt ein *Gestaltungsmodell* entwickelt (FTZ 1). Da sich diese Modellform beispielsweise zur Gestaltung zukünftiger Systeme eignet (Ulrich et al. 1984) und als Orientierungshilfe beziehungsweise Leitfaden für die Lösung bestehender Probleme fungieren kann (Lehner et al. 2008), wird sie für diese Arbeit als relevant erachtet. Zu diesem Zweck werden eingangs literaturbasiert inhaltliche Anforderungen definiert, welche Grundlage für die Modellentwicklung sind. Für das Gestaltungsmodell wird neben einem übergeordneten schematischen Rahmen ein besonderer Fokus auf die einzelnen Gestaltungscomponenten gelegt, welche aus den Anforderungen deduktiv erarbeitet werden. Eine empirische Studie in Anlehnung an Kano et al. (1984) integriert potenzielle Nutzer in die Entwicklung, welche die ermittelten Anforderungen nach Relevanz einstufen. (Kapitel 4)

Auf Basis des Gestaltungsmodells erfolgt die Entwicklung einer *Operationalisierungsmethode*, welche zum Ziel hat, das Gestaltungsmodell systematisch in eine Softwarearchitektur zu überführen (FTZ 2). Hierzu wird zunächst ein Ordnungsrahmen festgelegt, welcher auf einem etablierten Vorgehen bei der Entwicklung von Assistenzsystemen basiert und die Grobstruktur der Methode bildet. Die einzelnen Gestaltungscomponenten werden anschließend in den Ordnungsrahmen einsortiert und jeweils Handlungsalternativen dargelegt. (Kapitel 5)

Deskriptive Studie II

In der vierten Phase der DRM wird eine zweite deskriptive Studie mit dem Ziel der Anwendung und empirischen Evaluation durchgeführt. Es gilt hierzu, die Nützlichkeit der erarbeiteten Lösung zu bewerten. Die Evaluation erfolgt aus den drei Perspektiven *Unterstützungs-*, *Anwendungs-* und *Erfolgsevaluation*. Im Zuge der Unterstützungsevaluation wird untersucht, ob die Lösungen wie vorgesehen funktionieren und verwendbar sind. In der Anwendungsevaluation wird überprüft, ob die Lösungen zum gewünschten Zweck eingesetzt werden können und zuvor definierte Anforderungen erfüllt werden. Die Erfolgsevaluation erfolgt schließlich durch Anwendung in der Praxis. Hierbei wird der Nutzen der entwickelten Lösung überprüft. (Blessing und Chakrabarti 2009)

Zu diesem Zweck wird im ersten Schritt auf Basis von Gestaltungsmodell und Operationalisierungsmethode eine Softwarearchitektur entwickelt und prototypisch als ein

Softwaresystem umgesetzt. In diesem Zusammenhang erfolgt die Unterstützungsevaluation. Anhand von Nutzerstudien in Industrieworkshops wird formativ untersucht, ob die iterativ erarbeiteten Prototypen Unterstützung für die Zielgruppe bieten.

Im zweiten Schritt erfolgt die Anwendung des Softwaresystems in der Praxis. In diesem Zusammenhang wird die erarbeitete Lösung zunächst in einer Lernfabrik angewendet. Vertiefende Erläuterungen, warum sich eine Lernfabrik trotz der Zuordnung zum arbeitsorientierten Lernen eignet, werden in Abschnitt 6.2.3 dargelegt. Hierzu wird eine randomisierte Kontrollgruppenstudie durchgeführt, wobei die Experimentalgruppe unter Anwendung des TAS lernt, während die Vergleichsgruppe nach herkömmlichem Vorgehen unterrichtet wird. Weiterhin findet das erarbeitete TAS Anwendung in einem produzierenden Unternehmen. Zur Evaluation des Erfolgs werden in beiden Anwendungen Pre- und Posttests auf Basis definierter Lernziele durchgeführt und die Veränderung der erreichten Ergebnisse miteinander verglichen. Sowohl im Pre- als auch im Posttest wird auf Leistungstests und auf semi-strukturierte Interviews zurückgegriffen. Die Auswertung erfolgt unter Zuhilfenahme von Methoden der deskriptiven Statistik. Durch den Vergleich lässt sich abschließend eine Antwort auf FTZ 3 geben.

Um die summative Anwendungsevaluation durchzuführen, wird auf zwei Maßnahmen gesetzt. Jene inhaltlichen Anforderungen, welche die involvierten Anwendungsprobanden unmittelbar betreffen, werden durch diese mittels einer quantitativen Fragebogenstudie auf Einhaltung überprüft. Die weiteren inhaltlichen sowie die an Gestaltungsmodell und Operationalisierungsmethode gestellten formalen Anforderungen werden abschließend durch einen quantitativen Expertenfragebogen evaluiert.

3.3 Eingrenzung des Untersuchungsbereichs

Da die Gestaltung von TAS für ML-Anwendungen eine große Betrachtungsbreite ermöglicht, wird zur Spezifizierung in dieser Arbeit eine Begrenzung des Untersuchungsbereichs vorgenommen. Dazu werden Einschränkungen getroffen, welche in diesem Abschnitt näher charakterisiert werden.

Hinsichtlich des Einsatzzwecks

Das in der Folge zu gestaltende TAS soll sich, wie erläutert, für die arbeitsintegrierte Weiterbildung und dabei auf die Implementierung einer ersten ML-Anwendung eignen. Dies schließt im Gegenzug einige Anwendungsmöglichkeiten aus. So ist das Ziel nicht die kontinuierliche Nutzung im Betrieb. Hierauf haben sich andere Autoren in der Entwicklung ihrer Lösungen vertiefend konzentriert (siehe Abschnitt 2.3.4). Mit Hinblick auf ihre praktische Relevanz liegt der Fokus in der Lösung darüber hinaus auf ML-Anwendungen, welche sich mittels Algorithmen des Supervised und Unsupervised Learnings realisieren lassen (siehe Abbildung 3). Im Kontrast wird das Reinforcement Learning nicht betrachtet. Auch darüber hinaus gehende Anwendungen, wie beispielsweise die gegenwärtig vielfach in der Forschungslandschaft berücksichtigten Large Language Models sind nicht Gegenstand der vorliegenden Arbeit. Es ist anzunehmen, dass sich die in

der Folge entwickelten Inhalte auch auf solche Anwendungsfälle übertragen lassen. Dies konnte aus forschungsökonomischen Gründen allerdings nicht überprüft werden.

Hinsichtlich des technischen Umfangs

In Abschnitt 2.3.2 wurde der Begriff des intelligenten tutoriellen Systems eingeführt. Diese haben zum Ziel, auf Grundlage von ML-Lösungen Intelligenz in TAS zu bringen und Lerner durch personalisierte Inhalte beim Lernprozess zu unterstützen. Auf eine entsprechende Intelligenz und mögliche Personalisierung wird in dem hier entwickelten Ansatz verzichtet. Vielmehr wird auf feste Inhalte gesetzt, welche vor oder während der Entwicklung erstellt werden. Auch werden keine Analysen des Lernverhaltens und -fortschritts (Learning Analytics) vorgenommen.

Hinsichtlich der Software-Entwicklung

Im Zuge der Gestaltung des TAS wird die Einhaltung von Anforderungen aus den drei Disziplinen maschinelles Lernen, betriebliche Weiterbildung und digitale Assistenzsysteme berücksichtigt. Diese wurden in den Abschnitten 2.1 bis 2.3 eingeführt. Weitere darüber hinaus gehende Anforderungen insbesondere mit Hinblick auf die softwareseitige Umsetzung der entstehenden Architektur werden nicht dediziert betrachtet. Insofern eine inhaltliche Übereinstimmung mit den beschriebenen Themenfeldern vorliegt, werden diese selbstverständlich inzident integriert.

Hinsichtlich der abzubildenden Lernziele

Als Zielzustand wurde bereits zuvor die Ausbildung von produktionsbezogenen Prozessverantwortlichen und Teamleitern zu Citizen Data Scientists formuliert. Eine Ausbildung zu reinen Data Scientists, welche sich beispielsweise vollumfänglich mit Algorithmik befassen, wird nicht avisiert. Gleichermaßen liegen auch andere Berufsgruppen, wie beispielsweise Produktionsmitarbeiter sowie das mittlere oder obere Management außerhalb der Zielgruppe.

4 GESTALTUNGSMODELL FÜR TUTORIELLE ASSISTENZSYSTEME

In diesem Kapitel wird das Gestaltungsmodell für das TAS entwickelt. Dazu wird eingangs ein Einblick in die Modelltheorie gegeben (Abschnitt 4.1). Abschnitt 4.2 zeigt daraufhin die methodische Entwicklung des Gestaltungsmodells auf. Im Anschluss werden Anforderungen erörtert, welche sich aus der Forschungslücke ableiten lassen (Abschnitt 4.3). Auf Basis dieser werden sodann der schematische Aufbau und die einzelnen Subsysteme des Modells vorgestellt sowie diese final in den Aufbau eingeordnet (Abschnitt 4.4). Die konkretisierenden Komponenten werden im Anschluss weiterführend erläutert (Abschnitt 4.5). Abschnitt 4.6 beschließt das Kapitel mit einer Zusammenfassung.

4.1 Modelltheorie

Für das tiefere Verständnis werden in diesem Abschnitt zunächst grundsätzliche Merkmale und Funktionen von Modellen herausgearbeitet und somit eine für die vorliegende Arbeit einheitliche Begrifflichkeit geschaffen.

Modelle werden hinlänglich dazu verwendet, einen Ausschnitt der Realität vereinfacht darzustellen und somit das Grundproblem einer nur schwer abbildbaren Komplexität realer Systeme zu lösen (Patzak 1982; Holzmüller und Bandow 2010; Stachowiak 1973). Sie dienen somit zur Erklärung, Demonstration und Beschreibung (Töllner et al. 2010). Dazu erfüllen Modelle zwei Merkmale (Stachowiak 1973): Erstens lassen sie einzelne Attribute des realen Objekts außen vor und verkürzen dieses auf die tatsächlich relevanten. Zweitens sind Modelle pragmatisch. Das bedeutet, dass mit der Modellierung ein Zweck verfolgt wird, ein Modell zu einem bestimmten Zeitpunkt entwickelt und eine spezifische Zielgruppe avisiert wird. Ein Rückgriff auf Modelle eignet sich insbesondere bei der Planung und Gestaltung neuer Systeme und darin verlaufender Prozesse (Holzmüller und Bandow 2010).

Zur Beantwortung betriebswirtschaftlicher Fragestellungen und Gestaltung zukünftiger Systeme eignen sich vor allem Gestaltungsmodelle (Ulrich et al. 1984; Lehner et al. 2008). Sie stellen einen Bezug zu bestehenden wissenschaftlichen Ansätzen her, aus denen zu erfüllende Anforderungen definiert werden (Klotzbach 2007). Der Entscheidungsraum über Systemkomponenten lässt sich dazu anhand von Handlungsalternativen aufspannen, wobei Randbedingungen die Gestaltung flankieren (Patzak 1982). Aufgrund ihres interpretatorischen und gestaltungsorientierten Charakters lassen sich Gestaltungsmodelle als Soll-Modelle beschreiben, welche zukünftige Möglichkeiten visualisieren (Krcmar und Schwarzer 1994). Sie sind daher in der wissenschaftlichen Praxis etabliert und werden in zahlreichen Arbeiten verwendet (Klotzbach 2007; Begovic 2018; Frick 2024; Schreiber 2024). In Anlehnung an Patzak (1982) wird in Summe folgende Definition für Gestaltungsmodelle festhalten:

Definition Gestaltungsmodell:

Ein Gestaltungsmodell ist ein Soll-Modell, welches sämtliche Handlungsalternativen zur Gestaltung eines zukünftigen Systems enthält.

Bei der Entwicklung von Gestaltungsmodellen gilt es formale Grundsätze zu beachten, welche in der Literatur umfassend beschrieben werden. Mit Hinblick auf die vorliegende Arbeit lassen sich aus diesen die in Tabelle 5 dargestellten formalen Anforderungen an das Gestaltungsmodell (FAG) ableiten, welche im Kontext der Entwicklung zu berücksichtigen sind.

Tabelle 5: Formale Anforderungen für das Gestaltungsmodell

Nr.	Titel	Anforderung	Quelle
FAG 1	Vollständigkeit	Das Modell enthält alle für Nutzer erforderliche Informationen.	Moody und Shanks (1994); Schütte (1998)
FAG 2	Relevanz	In dem Modell sind ausschließlich die tatsächlich relevanten Elemente integriert.	Becker et al. (2012); Rosemann et al. (2012)
FAG 3	Übersichtlichkeit	Das Modell ist übersichtlich und intuitiv verständlich.	Becker et al. (2012); Rosemann et al. (2012)
FAG 4	Adaptivität	Das Modell kann mit geringem Aufwand nachträglich angepasst werden.	Moody und Shanks (1994); Schütte (1998)
FAG 5	Implementierbarkeit	Das Modell ist zeitlich, technisch und wirtschaftlich implementierbar.	Moody und Shanks (1994); Schütte (1998)

4.2 Methodisches Vorgehen bei der Entwicklung

Zur strukturierten Entwicklung des Gestaltungsmodells ist ein systematisches Vorgehen notwendig, welches die relevanten Entwicklungsschritte darlegt. Dieses wird in der Folge beschrieben. Das Vorgehen setzt sich in der Summe aus vier Schritten zusammen. Zunächst bedarf es der Ermittlung inhaltlicher Anforderungen an das Modell. Hierzu erfolgt eine wissenschaftliche Fundierung und anschließend eine detaillierte Erläuterung der Anforderungen. Diese basieren auf existierenden Lücken und dedizierten Anforderungen an TAS. (Abschnitt 4.3) Im zweiten Schritt erfolgt eine Beschreibung der Struktur. Hierbei wird erst der schematische Aufbau erörtert. Im Anschluss erfolgt eine Definition der Subsysteme und der Komponenten. Die Subsysteme bestehen dabei jeweils aus mehreren Komponenten. Letztere wiederum basieren auf den inhaltlichen Anforderungen und abstrahieren diese insofern notwendig. Die Subsysteme und Komponenten werden abschließend in den schematischen Aufbau einsortiert. (Abschnitt 4.4) Anschließend erfolgt eine Detailvorstellung der Komponenten. Dabei werden Umsetzungsbeispiele und Handlungsalternativen angeführt. (Abschnitt 4.5) Eine konsekutive Operationalisierungsmethode, welche in Kapitel 5 konzipiert wird und die Einhaltung von FAG 5 sichert, beschließt das Vorgehen. Abbildung 18 zeigt das Vorgehen grafisch auf.

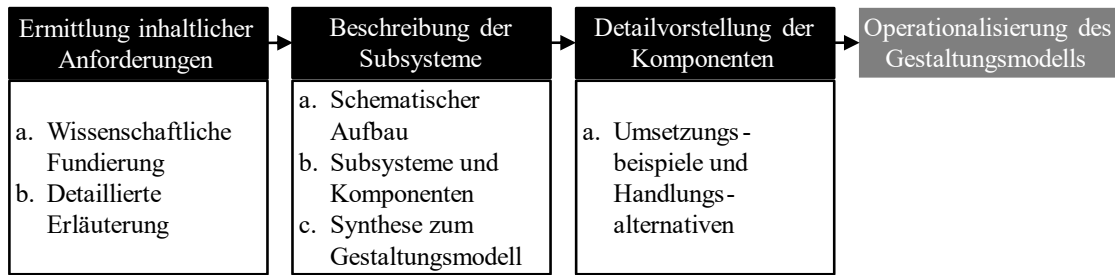


Abbildung 18: Vorgehen zur Entwicklung des Gestaltungsmodells

4.3 Ermittlung inhaltlicher Anforderungen an das Gestaltungsmodell

In diesem Abschnitt werden neben den formalen Anforderungen inhaltliche Anforderungen (IA) an das Gestaltungsmodell beschrieben. Dazu erfolgt zunächst eine Präsentation der wissenschaftlichen Fundierung. Die Anforderungen leiten sich aus den beschriebenen Defiziten aus Abschnitt 1.1, aus dem Stand der Wissenschaft und Technik (Kapitel 2) und aus spezifischen Anforderungen an TAS (siehe Abschnitt 2.3.3) ab. Eine derart umfassende Betrachtung hat zum Ziel, das Gestaltungsmodell vollständig zu konstruieren (FAG 1). Zudem sollen alle relevanten Komponenten enthalten sein (FAG 2). Im zweiten Schritt werden die inhaltlichen Anforderungen einzeln hergeleitet und erläutert.

4.3.1 Wissenschaftliche Fundierung der Anforderungen

Mit Hinblick auf die inhaltlichen Anforderungen an das hier entwickelte Gestaltungsmodell sind insbesondere solche Defizite relevant, die sich aus in der Vergangenheit durchgeführten ML-Projekten und den Bedürfnissen von KMU ergeben. In Abschnitt 1.1 wurden auf Basis von Literaturrecherchen bereits folgende Defizite aufgeführt, welche im Verlauf bestehender ML-Projekte aufgekommen sind:

- Mangelndes Grundlagenwissen unter Anwendern
- Mangelndes strukturelles Vorgehen bei der Durchführung von ML-Projekten
- Mangelnde Basis an Produktionsdaten
- Mangelnde Netzwerkinfrastruktur in Produktionsumgebungen

In Abschnitt 2.3.3 wurden zudem verschiedene Ansätze vorgestellt, wie TAS zu entwickeln sind. Diese werden für das bessere Verständnis der in den folgenden Abschnitten vorgenommenen Erläuterungen kurz wiederholt. Mir und Quadri (2009) fordern eine Betrachtung dreier Architekturbausteine. Sie unterscheiden dabei die Benutzeroberfläche, das Datenbankmanagementsystem und das Wissensmanagementsystem. Apt et al. (2018b) hingegen unterteilen ihren Aufbau in die Bausteine Ergonomie, Didaktik und Medium/Technologie. Sie fordern dabei, dass sich die Ergonomie an menschenzentrierten Kriterien und Gestaltungsprinzipien orientiert. Ein solches Vorgehen unterstützt zudem die Forderung nach menschenzentrierten ML-Anwendungen, wie in Abschnitt 2.1.1 eingeführt.

Lee et al. (2019) schlagen in ihrer Publikation darüber hinaus einen Ansatz zur Konzeptionierung einer automatisierten ML-Plattform vor. Diese erlaubt, den Arbeitsumfang von Experten zu minimieren und bietet Novizen einen Einstieg in den Themenkomplex. Zu diesem Zweck stellen sie Anforderungen auf, welche durch entsprechende Lösungen erfüllt sein müssen. Diese eignen sich aufgrund der thematischen Nähe auch für das in der Folge zu entwickelnde Gestaltungsmodell und umfassen folgende Aspekte:

- Frühzeitige Entscheidung über das zu wählende ML-Modell
- Verarbeitung von Trainingsdaten und Partitionierung in einen Trainings- und Testdatensatz
- Durchführung von Datenvorverarbeitungsschritten
- Extraktion von für Algorithmen relevanten Merkmalen
- Auswahl und Ausführung eines gewählten ML-Algorithmus
- Bereitstellung von Auswertungen des trainierten Algorithmus.

Auch Diamantis und Iakovidis (2021) befassen sich in ihrer Ausarbeitung mit der konzeptionellen Gestaltung von Assistenzsystemen zum Einsatz für ML-Anwendungen. Sie präsentieren dazu Anforderungen an entsprechende Lösungen. Diese fließen in die in der Folge vorgestellten Beschreibungen und inhaltlichen Anforderungen ein. Die Anforderungen der Autoren sind:

- Bereitstellung einer durchgängigen ML-Pipeline in einer generischen und strukturierten Weise.
- Integration technischer Details und Anwendungsszenarien, welche den Einsatz in beliebigen ML-Anwendungsfällen ermöglichen.
- Darstellung von Kennzahlen, die die Leistung von ML-Modellen zu bewerten erlauben.

4.3.2 Detaillierte Erläuterung der inhaltlichen Anforderungen

Auf Grundlage des vorangegangenen Abschnitts werden in diesem die inhaltlichen Anforderungen für das Gestaltungsmodell hergeleitet. Dazu werden einerseits die zuvor angeführten Ansätze und Forderungen herangezogen sowie andererseits weiterführende relevante Quellen aus der Literatur. Tabelle 6 fasst abschließend die inhaltlichen Anforderungen zusammen.

In ihren Forschungsergebnissen beschreiben Łapińska et al. (2021), dass Vertrauen involvierter Mitarbeiter in ML-Anwendungen eine Grundvoraussetzung zur erfolgreichen Arbeit mit diesen ist. Dazu sollten Mitarbeiter entsprechend geschult werden. Da im Kontext von Industrie 4.0 im Allgemeinen und ML im Spezifischen klassische formale Weiterbildungen seitens der Teilnehmer als nicht geeignet aufgefasst werden, ist für zukünftige Ansätze eine Neuausrichtung beispielsweise in Form von arbeitsintegriertem Lernen notwendig (siehe Abschnitt 2.4). Entsprechende Lernziele müssen dabei den Eigenschaften von arbeitsintegriertem Lernen standhalten. Auf Basis dessen lässt sich die folgende inhaltliche Anforderung festhalten:

IA 1: Das Gestaltungsmodell unterstützt die Erreichung von zu definierenden Lernzielen.

In ihrem Gestaltungsansatz für Assistenzsysteme führen Apt et al. (2018b) wie beschrieben an, dass Tutorialsysteme verschiedene didaktische Methoden betrachten sollten. Immerhin besteht arbeitsintegriertes Lernen aus der Kombination von informellem und non-formalem Lernen. Folglich ist zunächst ein Fokus auf spezifische Theorieinhalte zu legen. Mit Hinblick auf das non-formale Lernen eignet sich insbesondere das Prinzip der Exposition. Somit kann zunächst geschlussfolgert werden:

IA 2: Das Gestaltungsmodell ermöglicht non-formales Lernen durch das Prinzip der Exposition.

Weiterhin bedarf ein TAS Ansätze für das informelle Lernen. Es soll dadurch effizient einsetzbar sein. Zu diesem Zweck muss es lernförderlich gestaltet werden (siehe Abschnitt 2.3.2). Dies stärkt die Handlungsfähigkeit der Beschäftigten und erlaubt Unternehmen einen Mehrwert, da die Umsetzung im Betrieb durch Nutzer vereinfacht wird. Zudem stützt es das lebenslange Lernen, da Gelerntes zu einem späteren Zeitpunkt in neuen Szenarien angewendet werden kann. In der Summe dient eine lernförderliche Gestaltung eines TAS damit der Kompetenzentwicklung der Nutzer. (Dehnbostel 2018b) Auf Basis dessen wird zusammenfassend gefordert:

IA 3: Das Gestaltungsmodell ist lernförderlich gestaltet und erlaubt somit informelles Lernen.

Haben sich Unternehmen für einen ML-Anwendungsfall entschieden und befassen sich mit der Implementierung, so scheitert diese oftmals aufgrund mangelndem strukturellem Vorgehen (Ermakova et al. 2021). Dies impliziert im Gegensatz den Bedarf einer systematischen Unterstützung. Auch Sjödin et al. (2018) kommen in ihrer empirischen Studie zu dem Ergebnis, dass Unterstützungsansätze mit Fokus auf Nicht-ML-Experten ein schrittweises Vorgehen benötigen. Dies biete den Vorteil, dass notwendige Inhalte sukzessive durchlaufen werden. Folglich müssen neu zu entwickelnde Systeme folgende Anforderung erfüllen:

IA 4: Das Gestaltungsmodell leitet Nutzer systematisch durch die integrierten Schritte.

Zahlreiche Autoren zeigen auf, dass produzierende Unternehmen, und hier insbesondere solche des mittelständigen Spektrums, Herausforderungen bei der Aufnahme der Daten haben und zudem oftmals nicht über die notwendige Infrastruktur verfügen (Bauer et al. 2020; Metternich et al. 2021; Wuest et al. 2016; Gay et al. 2022). Immerhin bildet vor allem die Präsenz von Daten eine essenzielle Grundlage für das Training von ML-Modellen. Neu zu entwickelnde Ansätze sollten dieser Hürde begegnen und entsprechende Unterstützung liefern. So ist beispielsweise zu klären, durch welche Sensoren Daten aufgenommen werden können, wie diese transportiert und wie gespeichert werden. Folglich sind für neue TAS folgende Anforderungen festzuhalten:

IA 5: Das Gestaltungsmodell unterstützt die Planung einer Netzwerkinfrastruktur für den definierten Anwendungsfall.

IA 6: Das Gestaltungsmodell bietet Erläuterungen, welche Daten relevant sein können und wie diese aufgenommen werden können.

In ihrer Arbeit führen Lee et al. (2019) aus, dass die Auswahl des richtigen ML-Paradigmas (Supervised, Unsupervised, Reinforcement Learning) in realen Anwendungsfällen ein komplexes Problem darstellt, welches im Regelfall nicht trivial zu lösen ist. Abhängig von diesem unterscheidet sich jedoch das Vorgehen innerhalb eines TAS. Dies jedoch gilt umso mehr für die Realisierung von Anwendungsmöglichkeiten in der Produktion. Wie in Abschnitt 3.3 erläutert, fokussiert sich diese Arbeit auf die beiden Paradigmen Supervised und Unsupervised Learning, welche weiterführend durch ML-Modelle konkretisiert werden können. Für das Supervised Learning umfasst dies die Klassifikation und die Regression. Als Modelle des Unsupervised Learnings stehen beispielsweise die Anomaliedetektion und das Clustering zur Verfügung. Somit kann resümiert werden:

IA 7: Das Gestaltungsmodell konzentriert sich auf ein zu definierendes ML-Modell.

Gemäß Mir und Quadri (2009) benötigt ein TAS weiterhin Ansätze zur Datenspeicherung und eine GUI zur Visualisierung seiner Inhalte. Mit Hinblick auf die Datenspeicherung sind den Autoren zufolge geeignete Schnittstellen zur Verwaltung und zur Ermöglichung des Zugriffs auf die Daten notwendig. Als potenzielle Speichermedien können Datenbankmanagementsysteme fungieren (Bodendorf 2006). Zur Visualisierung unterstützen anschließend Werkzeuge wie Tabellen oder Diagramme. Hinsichtlich der GUI ist es nach Auffassung der Literatur vonnöten, dass diese menschenzentriert gestaltet ist (Apt et al. 2018b; Mehler et al. 2021). Dies erlaubt, dass Nutzer effektiv und effizient mit dieser arbeiten können und dass diese zu Zufriedenheit führt (siehe Abschnitt 2.3.3). Aufbauend auf den vorgestellten Erfordernissen lässt sich somit festhalten:

IA 8: Das Gestaltungsmodell besitzt einen geeigneten Ansatz für das Datenmanagement zum Speichern und Verarbeiten der erhobenen Daten.

IA 9: Das Gestaltungsmodell visualisiert seine Inhalte über eine menschenzentrierte grafische Benutzeroberfläche.

Letztlich stellen Apt et al. (2018b) dar, dass die Auswahl des Mediums von Relevanz für die Entwicklung eines TAS ist. Sie sollen dabei eine optimale Unterstützung in der Lernumgebung gewährleisten und können relevante Lerninhalte auf verschiedene Weisen vermitteln. Üblicherweise besteht die finale Wahl nach Ansicht der Autoren allerdings auf einem Technologiemix und kann entweder verschiedene digitale Medien umfassen oder digitale und analoge kombinieren. Um letztlich eine sinnvolle Entscheidung zu treffen, sind im Vorfeld die Lernumgebung und die Lerner detailliert zu analysieren. Aus diesen Erläuterungen kann final abgeleitet werden:

IA 10: Das Gestaltungsmodell wird durch eine geeignete Technologie praktisch umgesetzt.

Tabelle 6: Zusammenfassung der inhaltlichen Anforderungen

Nr.	Beschreibung
IA 1	Das Gestaltungsmodell unterstützt die Erreichung von zu definierenden Lernzielen.
IA 2	Das Gestaltungsmodell ermöglicht non-formales Lernen durch das Prinzip der Exposition.
IA 3	Das Gestaltungsmodell ist lernförderlich gestaltet und erlaubt somit informelles Lernen.
IA 4	Das Gestaltungsmodell leitet Nutzer systematisch durch die integrierten Schritte.
IA 5	Das Gestaltungsmodell unterstützt die Planung einer Netzwerkinfrastruktur für den definierten Anwendungsfall.
IA 6	Das Gestaltungsmodell bietet Erläuterungen, welche Daten relevant sein können und wie diese aufgenommen werden können.
IA 7	Das Gestaltungsmodell konzentriert sich auf ein zu definierendes ML-Modell.
IA 8	Das Gestaltungsmodell besitzt einen geeigneten Ansatz für das Datenmanagement zum Speichern und Verarbeiten der erhobenen Daten.
IA 9	Das Gestaltungsmodell visualisiert seine Inhalte über eine menschenzentrierte grafische Benutzeroberfläche.
IA 10	Das Gestaltungsmodell wird durch eine geeignete Technologie praktisch umgesetzt.

4.4 Subsysteme des Gestaltungsmodells

In diesem Abschnitt werden auf Basis der zuvor erörterten Anforderungen die einzelnen Elemente des Gestaltungsmodells aufgeführt. Dazu wird zunächst der schematische Aufbau beschrieben. Daraufhin erfolgt eine nähere Betrachtung der Elemente.

4.4.1 Schematischer Aufbau des Gestaltungsmodells

Um einen Rahmen für das in dieser Arbeit zu entwickelnde Gestaltungsmodell zu bekommen, erfolgt eine Orientierung an bestehenden Modellen. So entwickelt Begovic (2018) in seiner Arbeit ein Gestaltungsmodell bestehend aus den drei Stoßrichtungen Voraussetzungen, Gestaltungsfelder und Befähiger. Voraussetzungen beschreiben zu erfüllende technische und infrastrukturelle Maßnahmen. Gestaltungsfelder wiederum stellen die Kernelemente des Modells dar und umfassen zu betrachtende Inhalte. Befähiger letztlich sind solche Elemente, die für die Realisierung der Gestaltungsfelder nicht erforderlich sind, diese aber unterstützen.

Auch für das im Rahmen dieser Arbeit zu entwickelnde Gestaltungsmodell lassen sich Elemente der drei beschriebenen Stoßrichtungen ermitteln. Der Aufbau ist zudem übersichtlich gestaltet (FAG 3) und erlaubt ein nachträgliches Anpassen an hinzukommende neue Elemente (FAG 4). Entsprechend wird in der Folge der Grundaufbau des Modells von Begovic (2018) mit Adaptionen übernommen. So fordern Apt et al. (2018b) bei der Gestaltung von TAS eine Betrachtung von Design und Didaktik. Daher werden die Gestaltungsfelder des Modells in die Subsysteme *Design* und *Didaktik* unterteilt.

Da die spätere Operationalisierung des Gestaltungsmodells eine Softwarearchitektur darstellt, erfolgt die Beschreibung der Elemente anhand Begrifflichkeiten aus der Entwicklung von Softwarearchitekturen. Eine Softwarearchitektur ist die strukturierte oder hierarchische Anordnung der Komponenten eines Softwaresystems inklusive der Beschreibung ihrer Beziehungen (Balzert 2011). Sie besteht dem Autor zufolge dabei aus verschiedenen Subsystemen, welche Leser durch die Architektur führen und für sich allein betrachtet werden können. Subsysteme enthalten darüber hinaus Komponenten, welche sie weiter konkretisieren. Abbildung 19 stellt den konzeptionellen Aufbau des Gestaltungsmodells vor.




Abbildung 19: Schematischer Aufbau des Gestaltungsmodells, eigene Darstellung in Anlehnung an Begovic (2018)

4.4.2 Subsystem Voraussetzungen

Vor Beginn der Entwicklung ist es notwendig, die *Voraussetzungen* zu realisieren. In diesem Zusammenhang gilt es, drei Komponenten umzusetzen. So sind diejenigen Inhalte zu extrahieren, die der Zielgruppe hauptsächlich vermittelt werden sollen. Diese beinhalten unter anderem den konkreten Anwendungsfall sowie die Definition der Lernziele. Aus der Menge aller möglichen Inhalte muss folglich durch einen Experten eine Priorisierung vorgenommen werden, sodass der zeitliche Rahmen für relevante Themen sichergestellt ist und eine Entscheidung über den Ausschluss weniger relevanter Themen getroffen werden kann (Glass 2021). In diesem Zusammenhang ist das *ML-Modell* (IA 7) frühzeitig zu definieren. Der zweite Baustein des Subsystems sind die *Lernziele* (IA 1), welche durch die Nutzung des Gestaltungsmodells erreicht werden. Dabei ist zu beachten, dass die Lernziele vom gewählten ML-Modell abhängen. Zu unterscheiden ist hier beispielsweise die konkrete Zielgruppe oder der Zielzustand nach Beendigung der Nutzung. Letztlich muss an dieser Stelle die Wahl einer *Technologie* (IA 10) beziehungsweise eines Technologiemixes erfolgen. Die richtige Wahl ist dabei von weiteren didaktischen

Ansätzen, den Rahmenbedingungen des Lernens beziehungsweise den Lerninhalten sowie der Lernziele abhängig. Lerninhalte zum Beispiel sollten multimodal aufbereitet werden, um einen Mehrwert zu generieren (Ginns 2005).

4.4.3 Subsystem Design

Im Zusammenhang des Subsystems *Design* sind ebenso drei Komponenten zu berücksichtigen. Zur Verhinderung unstrukturierten Projektmanagements bedarf es zunächst eines Vorgehens, welches systematisch aufgebaut ist und alle relevanten Schritte umfasst. Dies ist durch die Integration eines *Prozessmodells* (IA 4) sichergestellt. Gleichzeitig Gegenstand vieler Prozessmodelle und spezifische Anforderung an neue Systeme ist die Integration von Unterstützung zum *Netzwerkinfrastrukturaufbau* (IA 5) und zur *Datengenerierung* (IA 6). Sie konkretisieren somit die entsprechenden, ohnehin enthaltenden, Schritte innerhalb des Prozessmodells. Eine Betrachtung dieser beiden Komponenten erlaubt eine höhere Praxisrelevanz und stellt sicher, dass spezifische Bedürfnisse von KMU umfasst werden. Wie von Mir und Quadri (2009) sowie von Balzert (2011) gefordert, benötigt ein TAS ein *Datenmanagementsystems* (IA 8) und eine *Benutzeroberfläche* (IA 9). Letzteres sollte dabei menschenzentriert gestaltet sein. Kriterien zur Realisierung von menschenzentrierter Gestaltung wurden in Abschnitt 2.3.3 erläutert.

4.4.4 Subsystem Didaktik

Im Zuge dieses Subsystems *Didaktik* sind zunächst Materialien zur *Exposition* (IA 2) zu integrieren. Mit Hinblick auf das non-formale Lernen sind dabei für den Themenkomplex notwendige Theorieinhalte zu ermitteln. Diese sollten im Anschluss unter Betrachtung der Lerner und der Lernumgebung gestaltet und letztlich in das TAS integriert werden. Dabei ist insbesondere zu entscheiden, ob eine oder mehrere Technologien zum Tragen kommen. Zur Sicherstellung informellen Lernens ist weiterhin der didaktische Aufbau des Assistenzsystems von Relevanz. In diesem Zusammenhang sind die Eigenschaften zur *Lernförderlichkeit* (IA 3) zu umfassen. Dazu bedarf es unter anderem ganzheitlicher Aufträge, zwischenmenschlicher Kooperationen und Entscheidungsspielraum.

4.4.5 Subsystem Befähiger

Die einzelnen Komponenten lassen sich durch Befähiger umrahmen. Diese orientieren sich an den Befähigern für das arbeitsintegrierte Lernen, welche umfänglich in Abschnitt 2.2.2 eingeführt wurden. Entsprechend werden sie hier lediglich zusammengefasst.

Eine *lernförderliche Unternehmenskultur* stellt den ersten Befähiger dar. Hierzu werden unternehmensseitig finanzielle, materielle und personelle Ressourcen zur Verfügung gestellt. Mittels Freistellungen oder Flexibilisierung der Arbeitszeit geben Unternehmen ihren Mitarbeitern zudem *Zeit zum Lernen*. Weiterhin beschreiben *Lernmotivationale Aspekte* Ansätze, um die Nutzer eines Tutorialsystems zum Lernen zu animieren. Hierunter fallen das situative Lernen, das selbstbestimmte oder selbstregulierte Lernen sowie das reflexive Lernen. *Soziale Unterstützung* im Unternehmen erlaubt es Lernern hierarchie-

und abteilungsübergreifend Kooperationen zu bilden. Communities of Practice beispielsweise schaffen Teams mit ähnlichem Lernziel. *Multiple Kontexte* verhindern letztlich träges Wissen und ermöglichen die Übertragung von Gelerntem auf ähnliche Anwendungsfälle.

4.4.6 Synthese zu einem Gestaltungsmodell

Nachdem zuvor die einzelnen Komponenten eingeführt wurden, werden sie abschließend in den schematischen Aufbau aus Abbildung 19 eingeordnet. Abbildung 20 stellt das zusammengefasste Gestaltungsmodell inklusive des schematischen Aufbaus und aller Gestaltungskomponenten dar.




Abbildung 20: Gestaltungsmodell für tutorielle Assistenzsysteme, eigene Darstellung in Anlehnung an Begovic (2018)

4.5 Detaillierung der Gestaltungsmodellkomponenten

In diesem Abschnitt werden die einzelnen Komponenten aus den Subsystemen näher erläutert sowie Handlungsalternativen zur Umsetzung aufgezeigt. Die Befähiger werden hier außen vor gelassen. Für ein tieferes Verständnis dieser wird auf die Erklärungen und Umsetzungsbeispiele in Abschnitt 2.2.2 verwiesen.

4.5.1 Subsystem Voraussetzungen

Im ersten Schritt werden demnach die Voraussetzungen näher beschrieben. Hierbei wird zunächst die Komponente Lernziele spezifiziert, bevor auf das ML-Modell und die Technologie eingegangen wird.

4.5.1.1 Komponente Lernziele

Lernziele geben Aussagen darüber, was Lerner wissen, verstehen und in der Lage sind zu tun, nachdem sie einen Lernprozess abgeschlossen haben. Sie können weiterhin in Kenntnisse und Fähigkeiten untergliedert werden. (Europäisches Parlament und Rat der Europäischen Union 2008) Gemäß der Literatur lassen sich Lernziele in vier Klassen unterteilen. Diese orientieren sich an der Einstufung von Kompetenzen in personale, fachlich-methodische, sozial-kommunikative sowie aktivitäts- bzw. umsetzungsorientierte Lernziele (siehe Abschnitt 2.2.1). Üblich für Weiterbildungen ist allerdings eine Fokussierung auf fachlich-methodische und sozial-kommunikative Kompetenzen.

Wie erläutert, ist das Zielbild der Arbeit, dass Nutzer eines TAS zu CDS weitergebildet werden. Zur strukturierten Betrachtung, welche Lernziele mit dessen Nutzung erreicht werden sollen, werden die Eigenschaften von CDS (siehe Abschnitt 2.1.3) herangezogen. Für die definierte Zielgruppe relevante ML-Kompetenzen zeigte darüber hinaus Abschnitt 2.2.4 auf. Um die Zielgruppe derart weiterzubilden, dass sie zu CDS werden, werden die identifizierten Kompetenzen mit den Eigenschaften von CDS gegenübergestellt. Anschließend wird auf Basis inhaltlicher Überschneidungen eine Schnittmenge gebildet. Folglich entsteht eine Konkretisierung des CDS, in der die Eigenschaften durch zielgruppenrelevante ML-Kompetenzen spezifiziert werden. Tabelle 7 zeigt das Ergebnis der Schnittmengenbildung auf. Felder mit einem X stellen die Schnittmenge dar, welche Input für spätere Konkretisierungen sind.

Tabelle 7: Auswahl relevanter Kompetenzen anhand des Zielbilds

ML-Kompetenzen der Zielgruppe	Eigenschaften eines CDS						
	Domänenwissen	Evaluation von Daten	Bewertung von ML-Algorithmen	Verständnis einfacher Algorithmen	Koordination von ML-Projekten	Interaktion mit verschiedenen Stakeholdern	
Grundlagenwissen über ML-Anwendungen aufweisen			X	X	X	X	
Identifikation möglicher ML-Anwendungsfälle für die Produktion					X		
Planung der Implementierung von ML-Anwendungen			X		X	X	
Geeignete Sensoren und Sensorsignale auswählen		X			X		
Mitarbeiter für den Einsatz von ML-Technologie begeistern, Change Management umsetzen							
Verschiedene Algorithmen des maschinellen Lernens verstehen				X			
Ergebnisse von ML-Modellen interpretieren		X	X				
Anpassungsfähig sein an veränderte personelle und organisationale Anforderungen							

ML-Kompetenzen der Zielgruppe	Eigenschaften eines CDS							
	Domänenwissen	Evaluation von Daten	Bewertung von ML-Algorithmen	Verständnis einfacher Algorithmen	Koordination von ML-Projekten	Interaktion mit verschiedenen Stakeholdern		
Problemlösungskompetenz bei aufkommenden Störungen im Kontext der ML-Implementierung aufweisen								
Interdisziplinäre Kommunikationskompetenz in Bezug auf ML-Anwendungen aufweisen (Top-Management, Mitarbeiter, u.a.)						X		
Reflexion des umgesetzten ML-Anwendungsfalls vornehmen		X	X					
Verständnis über die Prozesskette mitbringen	X							
Mensch-KI-Interaktion begreifen und Aufgaben daraus ableiten								
Ethische Aspekte in ML-Modelle einbeziehen								

4.5.1.2 Komponente ML-Modell

Mit Hinblick auf den Untersuchungsbereich dieser Arbeit wird das Gestaltungsmodell für Anwendungen des Supervised und Unsupervised Learnings konzipiert. Als Modelle des Supervised Learnings eignen sich die Klassifikation und die Regression, während Unsupervised Learning mittels Anomaliedetektion und Clustering umsetzbar ist (siehe Abbildung 21). Die frühzeitige Auswahl eines ML-Modells ist dabei von Relevanz, da das Vorgehen innerhalb eines TAS an spezifischen Stellen wesentlich vom Modell abhängt. So ist für die Klassifikation beispielsweise das Hinzufügen eines Zielwerts zu aufgenommenen Daten notwendig (siehe Abschnitt 2.1.1). Weiterhin müssen Datensätze für das Supervised Learning in einen Trainings- und Testdatensatz unterteilt werden. Letztlich unterscheiden sich abhängig vom ML-Modell die Leistungsmetriken (siehe Abschnitt 2.1.1), welche die Güte verwendeter Algorithmen bewerten. In ihrer Literaturrecherche ermitteln Nti et al. (2022), dass in der Produktionsforschung vorrangig Anwendungen des Supervised Learnings konzipiert werden. Hierbei ist den Autoren zufolge insbesondere die Klassifikation von Relevanz, welche einen Großteil der Anwendungen darstellt. Sie führen diesen Umstand auf weniger benötigte Rechenkapazitäten, höhere Ergebnisgenauigkeit sowie eine stärkere Vertrauenswürdigkeit dieser zurück.




Abbildung 21: Potenzielle ML-Modelle für ein TAS

4.5.1.3 Komponente Technologie

Gemäß der in Abschnitt 2.3.1 angeführten Literatur lassen sich stationäre und mobile Geräte unterscheiden (siehe Abbildung 22). Stationäre Geräte sind dabei unter anderem Bildschirme sowie Desktop-Computer. Mobile Endgeräte hingegen sind beispielsweise Laptops, Tablets, Smartphones, Wearables sowie Virtual- oder Augmented Reality-Anwendungen. TAS sollten dabei derart gestaltet sein, dass sie sich optisch ansprechend auf Bildschirmen verschiedener Größen darstellen lassen. Es ist darüber hinaus zu überlegen, inwiefern eine Kombination verschiedener Technologien mehrwertstiftend ist. Gemäß Apt et al. (2018b) bietet es sich an, eine Mischung von digitalen mit analogen Technologien zu erwägen oder verschiedene digitale Technologien zu kombinieren.

Apt et al. (2018a) und Apt et al. (2018b) führen in ihren Arbeiten Analysen bestehender TAS durch und klassifizieren darin die jeweils verwendeten Technologien. In den Ergebnissen fällt dabei auf, dass insbesondere Tablets von hoher praktischer Bedeutung sind. Im Zuge der Analyse vergleichbarer Assistenzsysteme (siehe Abschnitt 2.3.4) zeigte sich ein ähnliches Bild. Auch die darin untersuchten Artikel setzten ausschließlich auf Softwarelösungen über Tablets oder Personal Computer. Die beiden Ergebnisse lassen den Rückschluss zu, dass diese Technologien gegenwärtig als am relevantesten angesehen werden.




Abbildung 22: Mobile und stationäre Umsetzungsmöglichkeiten für ein TAS, eigene Darstellung in Anlehnung an Mark et al. (2021)

4.5.2 Subsystem Didaktik

Im zweiten Schritt werden die Komponenten des Subsystems Didaktik vertiefend behandelt.

4.5.2.1 Komponente Exposition

Bei der *Exposition* werden Lernmaterialien beispielsweise in Form von Bild, Text oder Ton dargestellt. Sie eignet sich somit insbesondere zum Erlernen von deklarativem Fachwissen. Der Aufbau der Inhalte ist dabei stark strukturiert. Entsprechende Lernmaterialien können in analoger oder digitaler Form präsentiert werden (Blumberg und Kauffeld 2021). Erpenbeck et al. (2016) liefern in diesem Zusammenhang verschiedene Umsetzungsbeispiele. Sie führen an, dass die Theorieinhalte exemplarisch durch internetbasiertes Lernen, und hier insbesondere in Form von sogenannten Massive Open Online Courses (MOOC), Podcasts, Videos, Printmedien sowie E-books angeboten werden können. Eine Zusammenfassung verschiedener Materialien zeigt Abbildung 23.




Abbildung 23: Zusammenfassung möglicher Expositionsmaterialien, eigene Darstellung in Anlehnung an Erpenbeck et al. (2016)

4.5.2.2 Komponente Lernförderlichkeit

Damit das TAS final im Kontext von arbeitsintegriertem Lernen eingesetzt werden kann, muss es nach Anforderung der Literatur lernförderlich gestaltet sein. Dazu stellen sich in Anlehnung an Hacker (2015) und Dehnbostel (2018b) verschiedene Anforderungen, welche in Abbildung 24 zusammengefasst sind.




Abbildung 24: Kriterien lernförderlicher Arbeitsgestaltung, eigene Darstellung in Anlehnung an Hacker (2015) und Dehnbostel (2018b)

Zunächst sollten zur Ermöglichung von Lernförderlichkeit *vollständige* oder *ganzheitliche* und nicht nur einzelne, spezifische *Aufträge* vorliegen. Diese umfassen unter anderem die Schritte Vorbereiten, Organisieren und Kontrollieren. Von Lernern werden somit einerseits verschiedene Kompetenzen gefordert. Andererseits erhöht dies deren Identifikation mit der gegebenen Aufgabe. Im Kontrast ist es nicht zielführend, wenn einzelne Schritte außen vor gelassen werden, da diese beispielsweise als nicht relevant erachtet werden.

Mit der Erzielung ganzheitlicher Aufträge gehen *verschiedene Teiltätigkeiten* einher. Sie bieten den Lernern Abwechslung und erhöhen in der Folge deren Motivation. Dieses Kriterium weist eine Schnittmenge mit der Verwendung von Prozessmodellen auf. Immerhin umfassen diese beginnend mit einer Ist-Analyse und Soll-Definition über Datenaufnahme bis hin zur Algorithmusverwendung verschiedene Teiltätigkeiten, welche von unterschiedlichen Anforderungen an die Beteiligten begleitet werden.

Weiterhin bedarf es für Nutzer an *Entscheidungsspielraum* in der Ausführung von Tätigkeiten. In der Anwendung eines TAS sollten Lerner exemplarisch durch Diskussionen in ihren CoPs oder Ausprobieren verschiedener Alternativen selbstständig Entscheidungen treffen. Der Handlungsspielraum lässt sich zudem gewährleisten, wenn Anwender verschiedene Entscheidungsalternativen in der Daten- und Algorithmusvorbereitung haben. Sie könnten zum Beispiel aufgefordert sein, zu entscheiden, ob sie eine Merkmalsselektion oder -extraktion als zielführender ansehen. Auch die Auswahl aus einer Vielzahl von

ML-Algorithmen stärkt die Lernförderlichkeit. Lerner müssen sich mit den einzelnen Algorithmen befassen und überlegen, welchen Algorithmus sie aus welchem Grund verwenden. Vor dem Hintergrund des Entscheidungsspielraums ist die Verwendung von AutoML hingegen in Frage zu stellen. Immerhin greift AutoML auf eine Vielzahl von ML-Techniken zurück und führt diese automatisiert aus. Den Nutzern bleibt dabei nur ein kleiner Entscheidungsspielraum.

Zudem fordert Dehnbostel (2018b) die Präsenz von Maßnahmen zur *Reflexion*. Dies umfasst dem Autor zufolge Möglichkeiten der strukturellen Reflexion und der Selbstreflexion. In diesem Zusammenhang sind exemplarisch Rückblicke an vorangegangene Schritte innerhalb des TAS denkbar. Diese könnten entweder unmittelbar am Ende eines Abschnitts erscheinen oder zu einem späteren Zeitpunkt und neue Teilergebnisse gegen an vorherige Eingaben spiegeln. Dies dient dem Zweck, das Erreichen ursprünglich gesteckter Ziele zu überprüfen.

Letztlich sollte ein TAS derart konzipiert sein, dass es der *individuellen Entwicklung* der Nutzer dient. Hierzu sollten Aufgaben dem Kompetenzniveau der Nutzer entsprechen und diese in der Ausführung weder unter- noch überfordern. Hieraus lassen sich zwei Maßnahmen ableiten. Zum einen sollten nur jene Aufgaben in einer Lösung enthalten sein, welche mit den erreichbaren Kompetenzen der Nutzer zusammenhängen. Mit Hinblick auf die Eigenschaften eines CDS sind an dieser Stelle keine Programmieraufgaben zu umfassen. Zum anderen bedarf es Maßnahmen zur Kommunikation mit anderen Experten im Unternehmen. Immerhin weisen Personen anderer Abteilungen andere Kompetenzen auf. Dies gilt exemplarisch für den Aufbau der Netzwerkinfrastruktur, in welche Mitarbeiter der Informationstechnik eingebunden sein sollten.

4.5.3 Subsystem Design

Zuletzt werden die Komponenten des Subsystems Design näher erläutert.

4.5.3.1 Komponente Prozessmodell

Wie dargestellt ist es notwendig, dass die Struktur innerhalb eines TAS einem Prozessmodell folgt. Einen Überblick über verschiedene Arten liefert Abschnitt 2.1.4. In diesem wurden unter anderem KDD, CRISP-DM, DMME und CRISP-ML(Q) vorgestellt. Einen vertiefenden Einblick in Prozessmodelle geben Mariscal et al. (2010). Sie analysieren diverse Modelle und extrahieren daraus Stärken und Schwächen. Aus Untersuchungen der letzten Jahre fällt auf, dass der CRISP-DM der am öftesten verwendete Prozess ist (Martinez-Plumed et al. 2021). Für diesen kommen jedoch Mariscal et al. (2010) zu dem Schluss, dass er nur festlegt, was zu tun ist, jedoch nicht, wie dabei vorgegangen werden sollte. Außerdem bezieht er domänenspezifische Hürden bei der Gewinnung und Verarbeitung von Daten nicht ausreichend ein (Montero 2008; Azevedo und Santos 2008). Andere Modelle wie DMME, CRISP-ML(Q) oder KDT-EA adressieren diese Aspekte detaillierter. Wie in Abschnitt 2.1.4 erläutert, lassen sich in der Summe hinsichtlich der dargestellten Phasen zwischen den einzelnen Modellen Gemeinsamkeiten und

Unterschiede feststellen. Tabelle 21 gibt hierzu eine Übersicht. Demnach können acht übergeordnete Phasen beginnend mit einer Ist-Analyse und Soll-Definition bis hin zur Verstetigung im Unternehmen ermittelt werden, welche sich in einzelnen Prozessmodellen wiederfinden (siehe Abbildung 25). Die Phasen dienen als Beschreibungsgrundlage für die methodische Umsetzung in Abschnitt 5.3.3.1.




Abbildung 25: Verallgemeinerter Ablauf der angeführten Prozessmodellphasen

4.5.3.2 Komponente menschenzentrierte Benutzeroberfläche

Zur Gestaltung der *menschenzentrierten Benutzeroberfläche* eignen sich gemäß oben stehenden Erläuterungen beispielsweise die Interaktionsprinzipien der DIN EN ISO 9241-110 (Deutsches Institut für Normung 2020). Demnach sind die Aufgabenangemessenheit, Selbstbeschreibungsfähigkeit, Erwartungskonformität, Erlernbarkeit, Steuerbarkeit, Robustheit gegen Benutzerfehler sowie die Benutzerbindung zu berücksichtigen. Die Norm selbst führt insgesamt 65 Empfehlungen zur Realisierung der einzelnen Prinzipien auf.

Um zu ermitteln, welche Empfehlungen aus Sicht von Nutzern tatsächlich relevant sind, wird im Rahmen dieser Arbeit eine Nutzerstudie auf Basis des Kano-Modells (Kano et al. 1984) durchgeführt¹⁴. Dieses stellt ein etabliertes Vorgehen zur Analyse und Bewertung von Kundenwünschen im Rahmen einer Produktentwicklung dar, weshalb es sich auch als Grundlage des Aufbaus von TAS eignet.

Mit Hinblick auf die Gestaltung von TAS werden die Empfehlungen der DIN EN ISO 9241-110 derart adaptiert, dass sie für den vorliegenden Anwendungsfall übertragbar sind. Hierfür werden die Formulierungen angepasst und der Umfang an Empfehlungen reduziert. Im ersten Schritt werden dazu ähnliche Empfehlungen gelöscht. Weiterhin werden mit Hinblick auf den Neuheitsgrad des im Rahmen dieser Arbeit entwickelten TAS Fragen zur externen Konsistenz weggelassen, da davon ausgegangen wird, dass Nutzer diese nicht beantworten können. Außerdem werden Fragen zu externen Einflüssen (Ressourcen und physischen Eingaben) nicht betrachtet, da dies als zu komplex für einen Prototypen erachtet wird. In Abschnitt 3.3 wurde bereits dargelegt, dass das hier entwickelte TAS nicht zur permanenten Verwendung im Produktionsumfeld geeignet sein soll, sondern als Medium im arbeitsintegrierten Lernen zu verwenden ist. Entsprechend dieser Einschränkung werden solche Empfehlungen nicht betrachtet, welche sich auf die langfristige Nutzung fokussieren. Auch Empfehlungen in Bezug auf automatische

¹⁴ Weiterführende Informationen zum Vorgehen bei einer Kano-Analyse finden sich in Anhang A3. Für eine Detailanalyse der Ergebnisse siehe darüber hinaus bei Rosemeyer (2025c).

Korrekturen können nicht inkludiert werden, da es hierzu weiterführender Bedienungsempfehlungen bedarf, welche in diesem Kontext nicht erhoben werden können. Letztlich hat das Endergebnis dieser Arbeit einen vorwettbewerblichen Charakter und daher keine Marktreife. Entsprechend werden Empfehlungen zur Benutzerbindung nicht berücksichtigt.

Nach Durchführung der Reduktion verbleiben 33 Empfehlungen der Norm im Fragebogen, was folglich in 66 Fragen resultiert. Der Fragebogen wird anschließend in digitalem Format an $n = 30$ potenzielle Nutzer aus dem produzierenden Gewerbe ausgeteilt.

Gemäß der Einordnung der Teilnehmer lassen sich drei Empfehlungen als *Basismerkmale* einstufen. Neun Empfehlungen stellen *Leistungsmerkmale* dar. Die Umsetzung von zehn Merkmalen hingegen würde *Begeisterung* hervorrufen. Letztlich können elf Merkmale als *unerheblich* eingeordnet werden. Als *Rückweisungsmerkmal* und als *fragwürdiges Merkmal* werden keine Empfehlungen eingestuft. Die Ergebnisse der Befragung fasst Tabelle 8 zusammen. Die Basis-, Leistungs- und Begeisterungsmerkmale werden im Anschluss inklusive Handlungsempfehlungen weiterführend erläutert.

Auffällig an den Ergebnissen aus der Kano-Analyse ist die Einordnung von Hintergrundinformationen und Erläuterungen. Diese wurden in der Umfrage oben als unerhebliches Merkmal eingestuft. Mit Hinblick auf die Verwendung des Gestaltungsmodells im Zuge des arbeitsintegrierten Lernens und den geforderten Maßnahmen zum non-formalen Lernen stellt diese Einordnung einen Widerspruch dar. Dies lässt sich unter Umständen durch den Hintergrund der Teilnehmer erklären: die an der Umfrage Beteiligten entstammen überwiegend der industriellen Praxis und haben somit keine oder nur geringe Kenntnisse über didaktische Ansätze. Mit Hinblick auf die Zielstellung dieser Arbeit sind diese Anforderungen dennoch umzusetzen.

Tabelle 8: Ergebnisse aus der Kano-Analyse

Basismerkmal	Leistungsmerkmal	Begeisterungsmerkmal	Unerhebliches Merkmal
Rückgängigmachen der letzten Eingabe	Möglichst viele Aufgaben automatisiert	Schlanke Darstellung	Produktionsbezogene betrachtete Anwendungsfälle
Abfangen fehlerhafter Eingaben	Kompatibilität auf unterschiedlichen Endgeräten	Darstellung des aktuellen Schritts	Standardauswahlmöglichkeiten
Einfache Sprache	Ausprobieren und problemfreies Abändern	Mehr als ein Sprachpaket	Aktuelle Aufgaben auf Display, Hintergrundinformationen im Netz
	Wiederaufgreifen zu späterem Zeitpunkt	Kurzvorstellung der einzelnen Schritte	Navigationsverlauf
	Automatische Speicherung im Hintergrund	Rückmeldungen zu spezifischen Eingaben	Spätere Relevanz von Eingaben

Basismerkmal	Leistungsmerkmal	Begeisterungsmerkmal	Unerhebliches Merkmal
	Hinweis auf Eingabefehler	Wiederaufgreifen von Informationen in einem zweiten Anwendungsfall	Rückmeldung über Eingabe
	Hervorheben von Textfeldern	Verschiebung von Fehlerkorrektur	Hintergrundinformationen per URL
	Bestätigung über erfolgreiche Eingabe	Präzise Fehlertexte bei falschen Eingaben	Springen zu anderen Schritten
	Optisch ansprechende Gestaltung	Vorschläge zur Fehlerkorrektur	Unterbrechung zu jedem Zeitpunkt
		Funktion zum Einreichen von Verbesserungsvorschlägen	Eingabe verbleibt im Textfeld
			Überspringen einführender Informationen

Basismerkmale

In der vorgestellten Umfrage sehen die Teilnehmer zunächst das *Rückgängigmachen einer Eingabe* (in der Folge als Undo bezeichnet) als Basismerkmal an. Entsprechende Undo-Modelle lassen sich gemeinhin in lineare Modelle und nicht-lineare Modelle unterteilen. Lineare Undo-Modelle speichern sämtliche Aktionen in einem Stack. Diese können im Anschluss chronologisch rückwärts abgearbeitet werden. Nicht-lineare Undo-Modelle hingegen erlauben die Auswahl und Bearbeitung aus einer Liste. Spätere Aktionen können somit übersprungen werden. (Mancini et al. 2001)

Als Basismerkmal fordern die Teilnehmer weiterhin das *Abfangen fehlerhafter Eingaben*. Eine fehlerhafte Eingabe definiert sich als Nichterfüllung einer festgelegten Anforderung und stellt damit eine Abweichung zwischen dem Ist-Verhalten und dem Soll-Verhalten dar (Spillner und Linz 2019). Zum besseren Verständnis werden im Folgenden weiterhin die Begriffe Fehlerwirkung und Fehlerzustand voneinander abgegrenzt. Eine Fehlerwirkung beschreibt die nach außen sichtbare Abweichung vom Soll-Zustand, welche beispielsweise durch falsche Ausgabewerte kenntlich wird. Ein Fehlerzustand hingegen zeigt die Ursache einer Fehlerwirkung an. Sie entsteht durch Programmierfehler oder vergessene Anweisungen. (Spillner und Linz 2019) Auf Grundlage einer Zielgruppencharakterisierung ist es in diesem Zusammenhang sinnvoll, etwaige Eingabefehler durch Nutzer zu antizipieren und durch entsprechende Funktionen frühzeitig zu unterbinden (Preim 2010). Abweichungen lassen sich dabei in verschiedene Fälle unterteilen. Dies umfasst zum einen die Option von zu wenigen oder überhaupt keinen Eingaben. Zum anderen können Nutzer auch zu viele, beziehungsweise redundante Eingaben vornehmen. Zu beachten ist dabei, dass sich eine Fehlerwirkung nicht unmittelbar nach Eintreten des Fehlerzustands zeigen muss (Spillner und Linz 2019).

Letztlich fordern die Teilnehmer eine *einfache Sprache*. Einen Ansatz, wie diese gelingen kann, bietet die DIN ISO 24495-1 (Deutsches Institut für Normung 2024a). Demnach

sollen visualisierte Informationen relevant, auffindbar, verständlich und hilfreich sein. Zur Wahrung der Relevanz bedarf es einer Analyse der Leser, deren Zielsetzungen und dem Lesekontext. Mit Hinblick auf die Zielgruppe dieser Arbeit ist folglich darauf zu achten, dass nur wenige und tatsächlich wichtige ML-Begriffe im TAS verwendet werden. Mit Hinblick auf die Auffindbarkeit sollen Informationen sinnvoll strukturiert sein, Leser anhand der Struktur relevante Inhalte leicht finden können, geeignete Überschriften gesetzt werden, und zusätzliche Informationen separat aufgeführt werden. Es sollte folglich eine sinnvolle Unterteilung zwischen Inhalten unmittelbar auf der GUI und zunächst versteckten Inhalten vorgenommen werden. Zur Verständlichkeit der Inhalte sind unter anderem Begriffe zu wählen, welche der Zielgruppe bekannt sind sowie Multimedia-Ansätze und Abbildungen zu verwenden. Es ist daher sinnvoll, Synonyme für ML-Fachbegriffe aufzugreifen. Letztlich sollen Informationen hilfreich sein. Dazu müssen sie kontinuierlich überprüft werden und diese durch die Zielgruppe kontinuierlich evaluiert werden. Einen zusammenfassenden Überblick über die Kriterien bietet Abbildung 26.




Abbildung 26: Kriterien einfacher Sprache, eigene Darstellung in Anlehnung an Deutsches Institut für Normung (2024a)

Leistungsmerkmale

Als Leistungsmerkmal stufen die Teilnehmer neun Aspekte ein. In der folgenden Beschreibung wird die Visualisierung auf unterschiedlichen Endgeräten außen vor gelassen, da mögliche Umsetzungen bereits im Abschnitt 4.5.1.3 thematisiert wurden.

Eine *Automatisierung von Aufgaben* bietet sich insbesondere im Zuge der Datenvorbereitung und Modellierung an. Eine Übersicht der dabei relevanten Schritte zeigt Abbildung 27. Anhand dieser werden mögliche Automatisierungsschritte vorgestellt.




Abbildung 27: Datenvorbereitung und Modellierung bei einer ML-Anwendung, eigene Darstellung in Anlehnung an Elshaw et al. (2019)

Im Zuge der Merkmalsvorbereitung kann exemplarisch die Ausreißeridentifikation automatisiert werden. Einen Ansatz dazu stellt die Berechnung des Interquartilsabstand dar.

Weiterhin kann zur Datenbereinigung eine automatisierte Entfernung von Nullwerten erfolgen. Im Zuge der Merkmalsextraktion und -selektion finden Berechnungen auf Grundlage mathematischer Verfahren statt, zum Beispiel Normalisierung und Erweiterung um statistische Merkmale. Beide lassen sich automatisiert vornehmen. Zudem bietet eine vorprogrammierte Automatisierung auch Mehrwert im Zuge des Modellaufbaus. So können verschiedene Algorithmen vorimplementiert sein, aus denen Nutzer dann eine Auswahl treffen. Dies ist vor dem Hintergrund von Bedeutung, dass das Programmieren von Algorithmen keine erforderliche Kompetenz von CDS ist. Gleiches gilt für das Anpassen von Hyperparametern. Ein Hyperparameter ist ein Parameter eines Lernalgorithmus und nicht eines Modells. Als solcher wird er nicht vom Lernalgorithmus selbst beeinflusst, sondern muss vor dem Training festgelegt werden und bleibt während des Trainings konstant. Verbreitete Ansätze dazu sind unter anderem die Rastersuche, Zufallssuche oder Ensemble Methoden. (Géron 2019) Einen verbreiteten Ansatz zur Umsetzung sämtlicher zuvor vorgestellter Schritte bietet die Verwendung von AutoML. Dabei wird automatisiert eine ML-Pipeline aufgebaut und somit der Aufwand für Nutzer reduziert. AutoML hat allerdings den Nachteil, dass Nutzer an Einfluss auf durchzuführende Schritte verlieren und der Lernumfang sinkt.

Im Kontext eines *problemfreien Ausprobierens und Abänderns* lassen sich verschiedene Handlungsalternativen beschreiben. Über eine Undo-Funktion können Nutzer ihre letzte Eingabe revidieren. Eine zugehörige Redo-Funktion erlaubt das Wiederherstellen einer zurückgenommenen Eingabe. Potenzial zur Realisierung bieten auch die Schritte Merkmalsvorbereitung und Modellaufbau. Immerhin sind jene Vorbereitungsschritte, welche später zum besten Algorithmusergebnis führen, ex ante nicht bekannt. Vielmehr muss anhand der Leistungsmetriken ex post ein Rückschluss auf diese gezogen werden. Entsprechend bedarf es Maßnahmen innerhalb eines TAS, durch die Nutzer mit geringem Aufwand verschiedene Kombinationen aus Merkmalsvorbereitung und Modellaufbau ausprobieren und abändern können. Dies betrifft insbesondere die Auswahl von Sensorsignalen, Extraktion und Selektion von generierten Merkmalen, das Training-Test-Verhältnis und die Auswahl eines Algorithmus.

Neben dem Abfangen von Eingabefehlern (siehe Basismerkmale) ist eine Identifikation solcher *Eingaben* relevant, welche zu einem Fehler geführt haben. Eine Zielgruppenanalyse und eine Festlegung möglicher Eingabefehler können hier unterstützen. Einen methodischen Ansatz dafür bieten beispielsweise Hinrichsen et al. (2016) in ihrer Arbeit. Sie fragen dabei nach Charakteristika der Zielgruppe, analysieren die Nutzungsumgebung und überlegen, wie Nutzer Eingaben in ein Assistenzsystem vornehmen.

Mit Hinblick auf eine *optisch ansprechende Visualisierung* der GUI liefert die DIN EN ISO 9241-112 (Deutsches Institut für Normung 2017a) weiterführende Grundsätze der Informationsdarstellung. Die Norm stellt dabei auf die Entdeckbarkeit, Ablenkungsfreiheit, Unterscheidbarkeit, eindeutige Interpretierbarkeit, Kompaktheit und Konsistenz von Informationen ab (siehe Abbildung 28). So wird unter anderem die Nutzungsgeschwindigkeit verbessert, der mentale Aufwand reduziert und die User Experience erhöht.

Außerdem verhindert die Beachtung der angeführten Grundsätze, dass Nutzer Probleme mit der Gebrauchstauglichkeit erfahren. Auf eine weiterführende Erläuterung wird an dieser Stelle verzichtet und auf die angegebene Quelle verwiesen.




Abbildung 28: Grundsätze der Informationsdarstellung, eigene Darstellung in Anlehnung an Deutsches Institut für Normung (2017a)

Mit Hinblick auf die geforderte *automatische Speicherung* lassen sich zwei Ansätze unterscheiden. Einerseits ist eine kontinuierliche Speicherung denkbar, welche unmittelbar durch eine neue Eingabe der Nutzer ausgelöst wird. Hierbei wird eine Speicherung nach jeder Eingabe vorgenommen. Optional kann eine Speicherung immer dann erfolgen, wenn eine Aufgabe abgeschlossen wurde und Nutzer zur nächsten übergehen. Dabei wird der jeweils aktuelle Stand gespeichert, ohne dass Nutzer dies explizit verlangen. Einem Verlust von Informationen wird somit vorgebeugt. Zu beachten ist in beiden Ansätzen, dass die Speicherung nicht die Performanz beeinträchtigen darf.

Die in der Kano-Analyse befragten Teilnehmer sehen zudem Bedarf in *positiven Rückmeldungen über getätigte Eingaben*. In seiner Arbeit unterscheidet Thesmann (2016) zwischen positiven und negativen Anzeigen. Negative Anzeigen sind Fehlermeldungen, welche zuvor bereits umfassend thematisiert wurden. Positive Anzeigen (betitelt als Rückmeldungen) hingegen zeigen an, dass eine Aktion erfolgreich ausgeführt wurde. Für sie gelten dieselben Kriterien wie für nicht-erfolgreiche Aktionen: unter anderem Höflichkeit und Präzision. Nutzern sollte folglich aufgezeigt werden, wenn alle Eingabefelder vollständig und fehlerfrei ausgefüllt sind.

Weiterhin lassen sich Anforderungen zum *Hervorheben von Texteingabefeldern* festhalten, welche sich an der DIN EN ISO 9241-125 (Deutsches Institut für Normung 2017b) orientieren. Demnach kann ein Eingabecursor automatisch an jener Position im Textfeld erscheinen, wo Nutzer die Eingabe durchführen werden. Außerdem sollte die Länge eines nicht-scrollenden Textfelds klar angezeigt werden. Der Norm folgend sind darüber hinaus Einschränkungen von Textfeldern zu visualisieren. Dies kann durch eine Eingabeaufforderung oder eine Feldhilfefunktion realisiert werden.

Letztlich bedarf es eines *Wiederaufgreifens* der vorgenommenen Eingaben in das TAS zu einem späteren Zeitpunkt. Hierbei lassen sich klassischerweise Funktionen zum Öffnen oder zum Importieren bestehender Projekte finden. Diese Funktionen sollten im Sinne der Konsistenz zu anderen Softwarelösungen auf der linken Fensterseite zu finden sein. Eine optionale Lösung stellen Nutzerprofile dar. In ihnen können daraufhin sämtliche

Nutzeradaptionen gespeichert werden. (Preim 2010) Die kognitive Last der Nutzer sinkt weiter, wenn Vorlagen für wiederkehrende Eingaben angeboten werden. Dadurch wird es leichter, sich auf wichtige Elemente zu konzentrieren. (Thesmann 2016)

Begeisterungsmerkmale

Als Begeisterungsmerkmal fordern die Teilnehmer zunächst eine *schlanke Darstellung der Benutzeroberfläche*. Hierzu kann exemplarisch der Grundsatz der Ablenkungsfreiheit (siehe Abbildung 28) aufgegriffen werden. Dieser liefert Empfehlungen zum Minimieren und Vermeiden von Unterbrechungen. Demnach sollen aufgabenbezogene Informationen deutlich von veränderlichen Informationen unterscheidbar sein. Außerdem sollen nicht notwendige Hintergründe, die die aufgabenbezogenen Informationen beeinträchtigen könnten, beseitigt oder verringert werden. (Deutsches Institut für Normung 2017a)

Weiterhin ist an dieser Stelle die Präsentation von Informationstexten in *verschiedenen Sprachen* anzuführen. Als geeignete Auswahl möglicher Sprachen können, neben der jeweiligen Erstsprache, solche dienen, welche weltweit am häufigsten gesprochen werden. Zum Zeitpunkt des Verfassens dieser Arbeit sind dies die Sprachen Englisch, Mandarin, Hindi und Spanisch (Ethnologue 2024).

In Bezug auf *verständliche Fehlertexte* sind vier Aspekte zu beachten, welche sich an den Erläuterungen von Thesmann (2016) orientieren. So sollen Fehlertexte unmittelbar nach Entdecken des Problems erscheinen und sich durch Konsistenz in Position, Struktur, Erscheinung und Verhalten auszeichnen. Fehlerhafte Felder werden dabei durch Dialogelemente deutlich gekennzeichnet und eine Erläuterung geboten, durch welche Korrekturmaßnahme Nutzer den aufgetretenen Fehler beheben können. Diese orientieren sich an der Sprache der Nutzer und sind eindeutig und höflich formuliert. Unter Umständen kann es sinnvoll erscheinen, Fehlertexte durch Symbole zu ergänzen, welche die Schwere eines Fehlers markieren. (Thesmann 2016) Tabelle 9 liefert Beispiele für unspezifische und präzise Fehlermeldungen.

Tabelle 9: Beispiele für präzise und unspezifische Fehlermeldungen, nach Preim (2010)

Unspezifische Fehlermeldungen	Präzise Fehlermeldungen
Syntaxfehler	Fehlende rechte Klammer
Illegale Eingabe	Geben Sie den Anfangsbuchstaben ein
Unzulässige Option	Folgende Optionen sind zulässig: [Option] [Erklärung]
Ungültiges Datum	Tagesangaben müssen zwischen 0 und 31 liegen
Falscher Dateiname	Dateinamen müssen mit einem Buchstaben beginnen

Ebenso ein Begeisterungsmerkmal stellt das *Wiederaufgreifen von Eingaben in einem zweiten Anwendungsfall* dar. Beispielsweise kann mittels entsprechender Funktionen das erneute Laden bereits vollendeter ML-Projekte erwogen werden. Einen anderen Ansatz stellt die Integration eines Wikis dar. Dies bietet darüber hinaus den Vorteil, dass es beim informellen Lernen unterstützen kann (siehe auch Erläuterungen in Abschnitt 2.2.2).

Bereits eingegebene Informationen können hierbei strukturiert abgespeichert und im Bedarfsfall erneut aufgegriffen werden.

Die *Visualisierung des aktuellen Schritts* ermöglicht es Nutzern, ihre Fortschritte zu verfolgen und die nächsten Schritte zu antizipieren. Es erhöht somit die Orientierung und Kontrolle. Zur praktischen Umsetzung eignen sich beispielsweise Fortschrittsanzeigen (Nielsen 2010). Dabei zeigt exemplarisch ein Fortschrittsbalken den erfüllten Aufgabenumfang relativ zum Gesamtaufgabenumfang an. Optional können schrittweise Indikatoren mittels nummerierter Schritte visuell darlegen, wann ein Schritt abgeschlossen ist. Einen anderen Ansatz liefert die Breadcumb-Navigation (Shneiderman und Plaisant 2005). Hierbei wird der aktuelle Stand als Teil eines hierarchischen Pfades dargestellt (zum Beispiel „Abschnitt > Schritt > Aufgabe“). Eine dritte Möglichkeit bieten Animationen oder Übergänge (Lidwell 2010). Diese können den Wechsel zwischen Zuständen visualisieren, was sich durch ein Fortschreiten entlang einer Achse oder durch das Erscheinen neuer Inhalte praktisch umsetzen lässt.

Eine *Kurzzvorstellung des aktuellen Schritts* lässt sich durch zwei Maßnahmen realisieren, welche sich nicht gegenseitig ausschließen und daher nebeneinanderstehen können. So bietet es sich an, den gegenwärtig zu durchlaufenden Abschnitt mit Hinblick auf Ziele und vorzunehmende Aufgaben zu Beginn des Durchlaufs vorzustellen. Dies bietet den Nutzern Orientierung und Sicherheit. Eine Zusammenfassung aller Abschnitte inklusive ihrer jeweiligen Aufgaben kann darüber hinaus an separater Stelle vorgenommen werden. Hierbei ist es zudem sinnvoll, eine übergeordnete Einführung in die Struktur des Prozessmodells anzuführen.

Nehmen Nutzer Aktionen vor, so sollte ein TAS in einer erkennbaren Weise reagieren und damit ein passendes Feedback (respektive *Rückmeldungen*) geben (Preim 2010). Feedback beschreibt die wahrnehmbare Systemreaktion, die nicht kontinuierlich, sondern ausschließlich zeitnah als Reaktion auf eine Nutzereingabe oder ein Systemereignis erscheint (Thesmann 2016). Diese kann visuell, akustisch oder haptisch erfolgen (Bowman et al. 2011). Hierbei ist von Relevanz, dass das Feedback zeitnah erscheint. Hingegen darf ein TAS Nutzer auch nicht mit zu viel Feedback überfordern (Thesmann 2016). Buttons können exemplarisch ihr Aussehen verändern sowie selektierte Menüeinträge hervorgehoben werden. (Preim 2010) Umsetzungsvorschläge, insbesondere mit Fokus auf Bearbeitungszeiten, werden bei letzterem Autor erläutert.

Darüber hinaus wird das *Verschieben von Fehlerkorrekturen* gewünscht. Demnach sollen Fehler nicht unbedingt sofort korrigiert werden müssen, sondern erst zu einem späteren Zeitpunkt. Da dieses Erfordernis einen Widerspruch zum Abfangen von Eingabefehlern darstellt, ist hierzu ein geeigneter Rahmen zu wählen. Es ist somit im Einzelfall zu überprüfen, ob dieses Erfordernis aufgegriffen wird – immerhin sind durch seine Abwesenheit keine Einbußen hinsichtlich der Nutzerbewertungen zu befürchten – und falls ja, auf welchem Detailniveau. Denkbar ist, dass Nutzer dennoch Eingaben auf der jeweils

präsentierten Seite vornehmen können und Fehlerkorrekturen erst vor dem Übergang in einen neuen Abschnitt vorgenommen werden müssen.

Hinsichtlich des *Einreichens von Verbesserungsvorschlägen* stellt sich die Fragestellung nach der Anonymität. Davon abhängig sind zwei Lösungen denkbar. Im Fall von gewünschter Anonymität eignen sich Nutzerumfragen. Hierbei können entweder permanent oder in regelmäßigen Abständen Abfragen erfolgen, bei denen Nutzer die Anwendung eines TAS bewerten und zudem Verbesserungsvorschläge angeben sollen. Optional können Kontaktdaten angegeben werden, bei denen deanonymisiert Verbesserungsideen vorgeschlagen werden können.

4.5.3.3 Komponente Datenmanagement

Im letzten Schritt ist das *Datenmanagement* zu konstruieren¹⁵. Es gilt dabei, Maßnahmen zu definieren, mit deren Hilfe Daten über standardisierte Schnittstellen transferiert werden können (Bodendorf 2006). Datenbanken beschreiben in diesem Kontext eine Sammlung an Daten, welche in einer logischen Beziehung zueinanderstehen. Aufgabe eines verbundenen Datenbankmanagementsystems ist es daraufhin, die Daten in den Datenbanken sinnvoll und zielorientiert zu verwalten. (Herrmann 2018) Das Datenmanagement muss in diesem Zusammenhang mehrere Ziele erfüllen (Bodendorf 2006):

- *Strukturierte Speicherung*: Daten müssen strukturiert gespeichert werden, sodass auf diese gezielt zugegriffen werden kann.
- *Verwaltung*: Es muss definiert sein, welche Nutzer auf welche Daten zugreifen können. Dabei ist auf Vertraulichkeit zu achten.
- *Nutzung*: Es gilt, durch geeignete Prozesse und Rollen sicherzustellen, dass auf Daten wieder zugegriffen werden kann und diese nicht im Unternehmensumfeld verschwinden.

In der industriellen Praxis lassen sich verschiedene Datenbankmanagementsysteme identifizieren (siehe Abbildung 29). Relationale Datenbanken eignen sich bei der Generierung strukturierter Daten, in denen Datenpunkte über einen Namen identifizierbar sind und für die verschiedene Merkmale bestehen. Relationale Datenbanken werden dabei üblicherweise mittels der Structured Query Language (SQL) umgesetzt. Hingegen erlauben not-only SQL (NoSQL)-Datenbanken die Verarbeitung unstrukturierter Datenmengen, welche über mehrere Systeme verteilt sind. Daten sind dabei nicht-relational gespeichert. Ein In-Memory-Datenbanksystem speichert und verarbeitet Daten direkt im Hauptspeicher. Dadurch ermöglicht es schnelle Zugriffe und hohe Verarbeitungsgeschwindigkeiten, was insbesondere bei großen Datenbeständen vorteilhaft ist. (Weber et al. 2022) Eine Zeitreihendatenbank ist geeignet, wenn Daten aus Zeitstempel und mehreren Werten bestehen. Abfragen erfolgen dabei über den Zeitstempel oder Zeitbereiche. (Bader et al. 2017) Objektorientierte Datenbanken haben Vorteile bei der gleichzeitigen Steuerung mehrerer

¹⁵ Aufgrund der Komplexität und Vielzahl an Möglichkeiten, können an dieser Stelle lediglich Unterstützungsansätze geliefert werden. Fertige Lösungen sind im Einzelfall zu bewerten.

Nutzeraktivitäten und eignen sich für verteilte Architekturen (Bitkom 2014). Data Warehouses letztlich lassen sich als spezielle Datenbanksysteme interpretieren, welche insbesondere zur Speicherung, Verwaltung und Analyse umfangreicher Datenbestände genutzt werden (Weber et al. 2022). Darüber hinaus können Datenbankmanagementsysteme in kommerzielle und nicht-kommerzielle Systeme unterschieden werden (Herrmann 2018).




Abbildung 29: Datenbanken in der industriellen Praxis, eigene Darstellung in Anlehnung an Bitkom (2014), Weber et al. (2022) und Bader et al. (2017)

Daten für ML-Anwendungen liegen oftmals in sogenannten relationalen Datenbanken vor und sind dabei auf mehrere Tabellen, Dokumente und Dateien verteilt. Ein gebräuchliches Format sind CSV-Dateien. (Géron 2019) Dieses wird für den Austausch und die Konvertierung von Daten zwischen verschiedenen Programmen verwendet (Shafranovic 2005). Ein weiteres verbreitetes Austauschformat ist die JavaScript Object Notation (JSON). Diese beschreibt ein Textformat für die Serialisierung von strukturierten Daten und repräsentiert vier primitive Datentypen (Zeichenketten, Zahlen, Boolesche Werte, und null) sowie zwei strukturierte Typen (Objekte und Felder). (Bray 2017) Einen alternativen Standard stellt die Extensible Markup Language (XML) dar. XML beschreibt eine Klasse von Datenobjekten mit Regeln zur Definition beliebiger Datentypen. Sie ist dabei weitreichend nutzbar, unterstützt die Realisierung einer Vielzahl an Anwendungen und darin kreierte Dokumente sind menschenlesbar und leicht interpretierbar. (Bray et al. 2008)

Gemeinhin ist es in diesem Zusammenhang sinnvoll, auf das Prinzip der Serialisierung zu setzen. Bei der Serialisierung wird der Zustand eines Objekts in einen Byte-Stream geschrieben. Dies ist nützlich, wenn der Zustand einer Applikation in einem dauerhaften Speicherbereich, wie beispielsweise einer Datei, gespeichert werden soll. Zu einem späteren Zeitpunkt können diese Objekte durch den Prozess der Deserialisierung wiederhergestellt werden. (Schildt 2019)

Aus den Beschreibungen lassen sich final Anforderungen festhalten, welche von einem Datenmanagement erfüllt sein müssen (Herrmann 2018; Kudraß 2015; Cordts et al. 2011; Härder und Rahm 2001; Lusti 2003):

- *Datenunabhängigkeit*: Daten können unabhängig von Hardware und Betriebssystem gespeichert werden.
- *Benutzerfreundlichkeit*: Benutzersprachen und GUI ermöglichen einen einfachen Umgang mit den Daten.
- *Mehrfachzugriff*: Verschiedene autorisierte Benutzer können gleichzeitig auf Daten zugreifen.
- *Flexibilität*: Daten ermöglichen einen wahlfreien Zugriff und kontinuierliche Verarbeitung.
- *Effizienz*: Zeiten für Abfragen, Verarbeitungen, Änderungen sowie Ergänzungen sind kurz.
- *Datenschutz*: Unterschiedliche Benutzergruppen haben unterschiedliche Zugriffs- und Änderungsrechte auf die Daten, wobei diese für manche gesperrt sind.
- *Datensicherheit*: Daten sind gegen System-, Programm-, Hardwareausfälle gesichert.
- *Datenintegrität*: Daten sind vollständig, korrekt und widerspruchsfrei gespeichert und bilden die Realität exakt ab.
- *Redundanzfreiheit*: Datenelemente sind lediglich einmalig gespeichert.

4.6 Zwischenfazit zum Gestaltungsmodell

In diesem Kapitel wurde die Entwicklung des Gestaltungsmodells als Grundlage tutorieller Assistenzsysteme vorgestellt. Dazu wurde im ersten Schritt grundlegende Modelltheorie erörtert und die strukturelle Herangehensweise zur Entwicklung des Gestaltungsmodell präsentiert. Im Anschluss wurden Anforderungen an das Modell ermittelt. Diese setzen sich in der Summe aus fünf formalen und zehn inhaltlichen Anforderungen zusammen. Basis der inhaltlichen Anforderungen sind Defizite in bestehenden ML-Projekten und dem Stand der Forschung sowie verschiedenen Gestaltungsansätzen für digitale Assistenzsysteme. Im zweiten Schritt wurde die Überführung der Anforderungen in das Gestaltungsmodell dargelegt. Dieses basiert auf einem Konzept aus der Literatur, welches für das in dieser Arbeit avisierte Ziel adaptiert wurde. Vier Subsysteme konkretisieren den Rahmen. In diese lassen sich insgesamt 13 Gestaltungskomponenten einordnen. Die Komponenten der Subsysteme *Voraussetzungen*, *Design* und *Didaktik* werden in der folgenden Operationalisierung aufgehen (siehe Kapitel 5). Jene Komponenten des Subsystems *Befähiger* hingegen sind nicht Gegenstand der resultierenden Softwarearchitektur, sondern werden erst im Zuge der Anwendung relevant (siehe Kapitel 6.2). Das in Abbildung 20 synthetisierte Modell sichert in Summe die Erreichung von FTZ 1. Zur strukturierten Umsetzung des Modells wird im folgenden Kapitel eine Methode entwickelt, welche Anwender in der Arbeit mit dem Modell unterstützt.

5 KONZEPTIONIERUNG DER OPERATIONALISIERUNGSMETHODE

In diesem Kapitel wird eine Methode konzipiert, welche für Softwarearchitekten die systematische Umsetzung des im vorangegangenen Kapitel beschriebenen Gestaltungsmodells ermöglicht. Dazu wird zunächst ein Einblick in die Methodentheorie gegeben (Abschnitt 5.1). Diese legen dar, wie eine Methode aufgebaut sein muss und welche formalen Anforderungen an sie gestellt werden. Im zweiten Abschnitt werden der Ordnungsrahmen sowie die einzelnen Phasen der Methode präsentiert und deren Methodenbausteine weiter konkretisiert (Abschnitt 5.2). Der darauffolgende Abschnitt liefert Entscheidungshilfen zur Umsetzung der Gestaltungsmodellkomponenten (Abschnitt 5.3). Ein Zwischenfazit zur Entwicklung bildet den letzten Abschnitt des Kapitels (Abschnitt 5.4).

5.1 Methodentheorie

Eine *Methode* stellt ein „auf einem Regelsystem aufbauendes Verfahren zur Erlangung von [wissenschaftlichen] Erkenntnissen oder praktischen Ergebnissen“ (Duden 2024b) dar. Sie beschreibt dabei in strukturierter Form, welche Tätigkeiten in welcher Reihenfolge ausgeführt werden sollen. Methoden sind zumeist praxisorientiert und auf einen bestimmten Anwendungsfall zugeschnitten. Ihr Zweck besteht darin, Anwender dabei zu unterstützen, die Komplexität des Anwendungsfalls besser zu bewältigen. Insgesamt tragen Methoden dazu bei, gesetzte Ziele auf eine effiziente Weise zu erreichen. (Lindemann 2009) Als Grundlage dienen oftmals Modelle, welche mittels einer Methode umgesetzt werden. Damit eine Verankerung einer Methode in der Forschung sichergestellt werden kann, bedarf es eines geeigneten Ordnungsrahmens (Pitsch 2014). Dieser gliedert die relevanten Elemente nach einer gewählten Struktur und hat zum Ziel, bei der Einordnung der Elemente und der Beziehung dieser zu unterstützen (Meise 2001). Bei der Gestaltung von Methoden müssen drei Prinzipien berücksichtigt werden (Haberfellner et al. 2015)¹⁶:

- *Vom Groben zum Detail*: Problemfelder und Lösungen sind zunächst weit zu fassen und dann sukzessive weiter einzugrenzen.
- *Denken in Varianten*: Ziel ist, sich nicht mit der erstbesten Lösung zufrieden zu geben, sondern zunächst einen umfassenden Überblick über Lösungsalternativen zu gewinnen.
- *Phasenablauf*: Die Realisierung einer Lösung ist in Phasen zu untergliedern, welche logisch und zeitlich voneinander getrennt sind. Die Lösungsfindung wird damit in Teilbereiche unterteilt.

Weiterhin lassen sich gemäß der Literatur bei der Entwicklung von Methoden formale Anforderungen (FAM) festhalten, welche in Tabelle 10 zusammengefasst sind.

¹⁶ In der angegebenen Quelle lassen sich vier Prinzipien finden. Da das vierte (Problemlösungszyklus als Mikro-Logik) für diese Arbeit keine Relevanz hat, wird es von der Beschreibung im Text außen vor gelassen.

Tabelle 10: Formale Anforderungen an die Methode

Nr.	Titel	Beschreibung	Quelle
FAM 1	Objektivität	Die Methode ist bei der Durchführung und bei der Interpretation von Ergebnissen unabhängig von subjektiven Einflüssen der Anwender.	Berekoven et al. (2009); Töpfer (2012)
FAM 2	Reliabilität	Die Methode führt unter gleichen Bedingungen wiederholt zum gleichen Ergebnis.	Berekoven et al. (2009); Töpfer (2012)
FAM 3	Validität	Die Ergebnisse der Methode lassen sich vollständig auf Eingangsgrößen zurückführen.	Berekoven et al. (2009); Töpfer (2012)
FAM 4	Generalisierbarkeit	Ergebnisse der Methode lassen sich auf eine größere Grundgesamtheit verallgemeinern.	Töpfer (2012)
FAM 5	Einfachheit	Die Methode ist leicht zu verstehen. Relevante Elemente sind dabei berücksichtigt und irrelevante ausgelassen.	Little (1970)
FAM 6	Anpassungsfähigkeit	Neu gewonnene Informationen und Elemente können nachträglich in die Methode integriert und ihre Schritte diesbezüglich abgeändert werden.	Little (1970)
FAM 7	Handhabbarkeit	Anwender können Eingangsgrößen schnell und einfach verändern und dabei dennoch verständliche Ergebnisse erhalten.	Little (1970)

5.2 Ordnungsrahmen und Phasen der Methode

Gemäß der im vorherigen Abschnitt beschriebenen Gestaltungsprinzipien erfolgt die Konzeptionierung der Methode vom Groben zum Detail. Entsprechend wird im ersten Schritt der Ordnungsrahmen festgelegt.

Wie bereits in Kapitel 2.3.3 gezeigt, sollten TAS nach Erkenntnissen der einschlägigen Forschungsergebnisse nach einem menschenzentrierten Vorgehen entwickelt werden. Hierzu hat sich das Vorgehen der DIN EN ISO 9241-210 (Deutsches Institut für Normung 2019a) etabliert. Aufgrund der Verbreitung in der Forschungslandschaft und zahlreicher Umsetzungen wird das Vorgehen auch im Kontext dieser Arbeit als relevant erachtet. Das Vorgehen besteht aus den fünf Phasen *Planen des Gestaltungsprozesses*, *Verstehen und Festlegen des Nutzungskontexts*, *Festlegen der Nutzungsanforderungen*, *Erarbeiten von Gestaltungslösungen* sowie *Evaluieren der Gestaltung*. Im Zuge der zweiten Phase sind laut Norm die Nutzer und deren Ziele zu beschreiben. Mit Hinblick auf die Fokussierung der vorliegenden Arbeit auf Prozessverantwortliche und Teamleiter, welche bereits umfassend in Abschnitt 2.1.3 charakterisiert wurden, wird zur Verhinderung von Redundanz die zweite Phase der Norm außen vor gelassen. Eine weiterführende kritische Diskussion dieser Reduktion findet sich in Abschnitt 5.4. Die Phasen sind zunächst in der genannten Reihenfolge zu durchlaufen. Insofern im Zuge der Operationalisierung als notwendig erachtet, sind Verbesserungsschleifen zu nehmen. Für eine ausführliche Beschreibung der einzelnen Phasen sei auf Abschnitt 2.3.3 verwiesen. Zur Umsetzung des Gestaltungsmodells werden die einzelnen Komponenten in die Phasen des Ordnungsrahmens

eingeordnet. Da die vorgelagerte Planungsphase keine Komponenten enthält, wird diese erst in Abschnitt 5.3 näher beschrieben.

Festlegen der Nutzungsanforderungen

In der ersten Phase gilt es, die Komponenten des Subsystems *Voraussetzungen* zu erarbeiten. Dies sind zum einen die Definition von *Lernzielen* (IA 1) und zum anderen die Auswahl eines *ML-Modells* (IA 7). Die Ergebnisse beider Schritte leiten sich dabei aus dem Kompetenzbedarf der Zielgruppe ab. Insofern notwendig, müssen darüber hinaus weitere notwendige Anforderungen beschrieben werden. Dies umfasst beispielsweise ergonomische Aspekte, Gebrauchstauglichkeitsanforderungen oder organisatorische Anforderungen (Deutsches Institut für Normung 2019a). Letztlich ist in diesem Zusammenhang eine *Technologie* (IA 10) zu wählen, welche das Gestaltungsmodell final in einer Softwarelösung realisiert. Gemäß der Norm können in dieser Phase potenzielle Nutzer eingebunden werden.

Erarbeiten von Gestaltungslösungen

Die zweite Phase befasst sich mit dem Erstellen von konkreten Lösungen. Hierbei kommen die Komponenten der Subsysteme *Design* und *Didaktik* zum Tragen, welche integrativ umgesetzt werden. Demnach ist es zunächst notwendig, ein *Prozessmodells* (IA 4) auszuwählen. Dieses bildet im Sinne von Mir und Quadri (2009) das Wissensmanagementsystem und damit den logischen Fluss innerhalb des TAS. Um das geforderte Lernen im Arbeitsprozess zu ermöglichen, muss dieses daraufhin durch die Komponenten aus dem Subsystem *Didaktik* erweitert werden. Hierzu wird gefordert, dass das TAS *lernförderlich* (IA 3) ist. Daraufhin kann das *Datenmanagement* (IA 8) realisiert werden. In diesem Zusammenhang müssen Entscheidungen getroffen werden, welche Daten wie zu integrieren, speichern und verarbeiten sind. Im Anschluss kann die *menschzentrierte Benutzeroberfläche* (IA 9) aufgesetzt werden. Letztlich ist zu überlegen, wie verschiedene *Expositionsmaterialien* (IA 2) sinnvoll in das Prozessmodell integriert werden können.

Evaluation von Gestaltungslösungen

Letztlich gilt es, die erzeugten Gestaltungslösungen zu evaluieren. Hierzu haben sich in der Literatur verschiedene Methoden etabliert, welche beispielsweise auf die Evaluation während der Entwicklung abstellen oder auf die Evaluation nach Beendigung der Entwicklung. Einzelne Methoden werden dazu im Abschnitt 5.3.4 näher beschrieben.

Abbildung 30 fasst die einzelnen Phasen mit den zugeordneten Subphasen zusammen. Mit Hinblick auf FAM 5 wird dabei auf eine leichte Verständlichkeit geachtet. Eine Darstellung unter Verwendung der Symbole der Business Process Model and Notation (BPMN) findet sich darüber hinaus in Abbildung 51 in Anhang A4.




Abbildung 30: Operationalisierungsmethode mit Gestaltungskomponenten, eigene Darstellung in Anlehnung an Deutsches Institut für Normung (2019a)

5.3 Detailvorstellung der Phasen

In diesem Abschnitt werden die einzelnen Phasen der Methode näher erläutert. Dabei werden verschiedene Lösungsalternativen und leitende Schritte betrachtet und somit eine objektive (FAM 1), reliable (FAM 2) und valide (FAM 3) Anwendung ermöglicht. Die Alternativen sind in der praktischen Realisierung einzelfallabhängig mit Hinblick auf Relevanz und Umsetzbarkeit zu bewerten (FAM 7). (Haberfellner et al. 2015)

5.3.1 Planen des Gestaltungsprozesses

Das Vorgehen der DIN EN ISO 8241-210 fordert im ersten Schritt eine umfassende Planung des Prozesses. Demnach sind zu einem frühen Zeitpunkt sämtliche Nutzungsphasen wie Konzeption, Gestaltung, Implementierung und Wartung zu betrachten. Insbesondere muss bewertet werden, in welcher Beziehung die Gebrauchstauglichkeit zum Zweck des TAS steht und welche Risiken mit der Nutzung einhergehen. Dazu sollten Entwickler Kompetenzen aus verschiedenen Disziplinen wie Arbeitswissenschaften, Domänenexpertise und ML-Expertise aufweisen. Auch ist zu überlegen, wie Nutzerrückmeldungen eingeholt werden können. Letztlich sind Iterationen zu planen. Zusammenfassend sind in dieser Phase folgende Schritte zu durchlaufen (Deutsches Institut für Normung 2019a):

- 1. Identifikation geeigneter Methoden in den einzelnen Phasen zur Gewährleistung einer menschenzentrierten Gestaltung**
- 2. Beschreibung verantwortlicher Personen mit unterschiedlichen Kompetenzen im Entwicklungsteam, unter anderem:**
 - a. Arbeitswissenschaft

- b. Domänenwissen
- c. ML-Expertise
- d. Didaktik
- e. Informationstechnik
- 3. Erstellung eines Maßnahmenplans zum Einholen von Nutzerrückmeldungen**
 - a. Formative oder summative Evaluation
 - b. Qualitative oder quantitative Studien
- 4. Entwicklung eines geeigneten Zeitplans mit Iterationen und Meilensteinen**

5.3.2 Festlegen der Nutzungsanforderungen

Gemäß Abbildung 30 bedarf es im nächsten Schritt der Ermittlung von Nutzungsanforderungen. Zu diesem Zweck ist eine Anforderungsanalyse vorzunehmen. Unter einer solchen ist die systematische und iterative Vorgehensweise zu verstehen, welche zum Ziel hat, eine mit allen Stakeholdern abgestimmte Systemspezifikation zu erarbeiten. Sie dient folglich dem Erkennen von Zielen und Bedürfnissen aus Sicht der Nutzer. (Broy und Kuhrmann 2021) Zur Zielerreichung werden die im Gestaltungsmodell aufgestellten Voraussetzungen *Lernziele*, *ML-Modell* und *Technologie* weiterführend erarbeitet.

5.3.2.1 Auswahl eines ML-Modells

Im ersten Schritt ist das zu betrachtende ML-Modell auszuwählen. In diesem Zusammenhang ist zu überlegen, welche spezifische Problemstellung industrieller Unternehmen adressiert werden soll und welches ML-Lernparadigma dafür geeignet ist. Tabelle 11 gibt auf Grundlage der zitierten Publikationen in Abschnitt 2.1.2 eine Übersicht über verschiedene Anwendungsfälle und jeweilige mögliche ML-Modelle. Diese sind dabei nicht zwingend eindeutig. Vielmehr können unter Umständen mehrere ML-Modelle in Betracht gezogen werden. Zur Entscheidung über das Lernparadigma ist im Anschluss zu beantworten, ob Datenlabel mit akzeptablem Aufwand generierbar und den Daten zuschreibbar sind. Zu beachten ist dabei, dass das Ermitteln und Ergänzen von Labels zeit- und ressourcenintensiv ist. Hingegen überwiegt die Erklärbarkeit von Algorithmen des Supervised Learnings gegenüber solchen des Unsupervised Learnings. Das Vorgehen zur Auswahl eines ML-Modells kann in der Summe wie folgt beschrieben werden:

- 1. Identifikation des Ziels der Anwendung**
 - a. Kategorisierung von Produktionsdaten: Klassifikation
 - b. Numerische Prognose: Regression
 - c. Erkennen von Ausreißern: Anomaliedetektion
 - d. Identifikation von Clustern in unstrukturierten Daten: Clustering
- 2. Überprüfung, ob Label zu den Produktionsdaten ergänzt werden können**
 - a. Ja: Überwachtes Lernen (Klassifikation, Regression)
 - b. Nein: Unüberwachtes Lernen (Anomaliedetektion oder Clustering)

Tabelle 11: Anwendungsfälle und respektive ML-Modelle

Anwendungsfall	ML-Modell
Prädiktive Instandhaltung	Regression
Zustandsüberwachung	Klassifikation, Anomaliedetektion
Prädiktive Qualitätssicherung	Klassifikation, Regression
Modellierung des Verhaltens von Werkzeugmaschinenkomponenten und Bauteilen	Klassifikation, Regression
Vereinfachung der Ursachenfindung	Regression, Clustering, Klassifikation
Prognose der Overall Equipment Effectiveness	Regression
Unterstützung der Mitarbeiter bei der Identifikation richtiger Komponenten	Klassifikation
Überwachung von Energieverbräuchen	Klassifikation, Regression, Anomaliedetektion

5.3.2.2 Definition von Lernzielen

Auf Grundlage des Anwendungsfalls erfolgt im Anschluss die Definition von spezifischen Lernzielen. Hierbei sollte in Anlehnung an Glass (2021) wie folgt vorgegangen werden:

- 1. Aufgreifen des zuvor definierten ML-Anwendungsfalls**
 - a. Charakteristika des Anwendungsfalls und Modells bestimmen
 - b. Definition von Anforderungen an die Zielgruppe
 - c. Priorisierung von als relevant eingestuften Inhalten
- 2. Durchführung einer Kompetenztransformation**
 - a. Definition der Hauptkompetenzen
 - b. Definition der Teilkompetenzen
 - c. Zuordnung von relevanten Wissen- und Handlungselementen

Zur Strukturierung relevanter Lernziele ist daher eine Kompetenztabelle zu entwickeln, wie beispielsweise von Abel et al. (2013) vorgeschlagen. In dieser werden zunächst die in einer Schulung zu entwickelnden zentralen Kompetenzen (Hauptkompetenzen) formuliert. Für diese lassen sich die Eigenschaften eines CDS (Abschnitt 2.1.3) nutzen. Die Hauptkompetenzen sind im zweiten Schritt um Teilkompetenzen zu ergänzen. Diese sind in der Form „Die Teilnehmer besitzen die Fähigkeit, [Beschreibung] [Taxonomiestufe]“ (Abele et al. 2015a) zu formulieren. Etablierte Ansätze für die Taxonomiestufe bieten die Einteilungen von Bloom (1956) und Anderson et al. (2001). Als mögliche Teilkompetenzen eignen sich jene, für welche eine Schnittmenge mit den Eigenschaften von CDS erarbeitet wurde (siehe Abschnitt 4.5.1.1). Im letzten Schritt erfolgt eine Konkretisierung zugehöriger Handlungen sowie einer Einordnung in spezifische Wissensarten (Abel et al. 2013). Diese untergliedern sich nach Tenberg (2011) in Professions-, Begründungs- und

Bezugswissen. Eine exemplarische Struktur einer resultierenden Kompetenztabelle visualisiert Tabelle 12.

Tabelle 12: Exemplarische Kompetenztabelle, eigene Darstellung in Anlehnung an Abel et al. (2013)

Hauptkompetenz	Teilkompetenz	Handlung	Professionswissen	Begründungs-/Bezugswissen	Taxonomiestufe
Fähigkeit, ML-Grundlagen zu verstehen und zu erklären	Fähigkeit, Grundlegende Begriffe im Kontext von ML-Anwendungen beschreiben zu können	KI und ML definieren können, Lernparadigmen beschreiben können	Kenntnis über Definitionen von KI und ML, Kenntnis über verschiedene Lernparadigmen	Verständnis, warum sich v.a. Supervised und Unsupervised Learning in der Produktion eignen	Verstehen

5.3.2.3 Wahl der Technologie

Als letzte Voraussetzung gilt es, eine geeignete Technologie auszuwählen. Zur Festlegung dieser Komponenten wird auf die in der Kano-Analyse (siehe Abschnitt 4.4.3) gestellte Frage nach der Visualisierung auf unterschiedlichen Endgeräten eine Antwort gegeben. Für die Technologiewahl sind zunächst Fragen zur Mobilität und zur Umgebung zu klären (Apt et al. 2018b). Im Anschluss sind Rechenleistung und Netzwerkanforderungen zu definieren:

- 1. Identifikation, ob das Lernen an einem festen Platz und zu einer festen Zeit erfolgen soll**
 - a. Ja: Desktop-Computer
 - b. Nein: Tablet, Handy, Virtual und Augmented Reality
- 2. Ermittlung der erforderlichen Rechenleistung und der Datensatzgröße**
 - a. Gering: Tablet, Handy
 - b. Hoch: Desktop-Computer, Laptop
 - c. Unklar: Virtual und Augmented Reality
- 3. Identifikation von Netzwerkanforderungen**
 - a. Online-Unterstützung: Laptop, Tablet, Handy, Desktop-Computer
 - b. Offline-Funktionalität: Tablet mit lokaler Datenbank, Augmented- und Virtual-Reality-Brillen mit Edge-Processing

Anhang A5 liefert eine Übersicht von möglichen Kriterien und bewertet jeweils die vorgestellten Technologien dahingehend.

5.3.3 Erarbeiten von Gestaltungslösungen

Nachdem im vorherigen Schritt die Nutzungsanforderungen präzisiert wurden, steht nun die Entwicklung von Gestaltungslösungen im Fokus. Hierzu werden die Komponenten

aus den Subsystemen *Design* und *Didaktik* adressiert. Gemäß Abbildung 30 erfolgt dies integrativ, indem beide Bereiche behandelt werden.

5.3.3.1 Auswahl eines Prozessmodells

Die folgende Beschreibung stellt die einzelnen vorgestellten Prozessmodelle gegenüber und liefert damit eine Entscheidungsunterstützung für die Auswahl eines Prozessmodells. Entwickler müssen sich in diesem Zusammenhang die Frage stellen, wie viel Struktur innerhalb des Modells notwendig ist. Weiterhin ist zu klären, ob Flexibilität und Iterationen gewünscht sind. Letztlich ist zu entscheiden, ob Charakteristika der Produktion explizit Berücksichtigung finden sollen. Die folgende Auflistung fasst die Fragen zusammen.

1. Ermittlung des Umfangs an Struktur

- a. Eher viel: DMME, CRISP-ML(Q), CRISP-DM, DASC-PM, AIMM, KDT-EA
- b. Eher wenig: KDD, SEMMA

2. Ermittlung des gewünschten Umfangs an Iterationen im Modell

- a. Eher viele: CRISP-DM, DMME, CRISP-ML(Q), DASC-PM, KDT-EA
- b. Eher wenige: KDD, SEMMA, AIMM

3. Festlegung, ob Charakteristika der Produktion umfasst werden sollen

- a. Ja: AIMM, KDT-EA, DMME, CRISP-ML(Q)
- b. Nein: KDD, SEMMA, CRISP-DM, DASC-PM

Im Folgenden werden für relevante Schritte Vorschläge zur praktischen Ausgestaltung gegeben. Hierbei wird auf die generischen Betitelungen aus Abschnitt 2.1.4 gesetzt. Auf Grund von Überschneidungen zwischen den Prozessmodellen lassen sich die Beschreibungen für sämtliche Prozessmodelle verwenden. Die Erläuterungen werden jeweils am Ende eines Absatzes in Form eines systematischen Vorgehens zusammengefasst.

Ist-Analyse/Soll-Definition

Im Zusammenhang des ersten Schritts bedarf es zunächst Maßnahmen, um darlegen zu können, wie das zu betrachtende Produktionsproblem Auswirkungen auf den Betrieb des Unternehmens hat. Hierzu ist für spätere Anwender eines TAS Ansätze zu unterbreiten, damit sie entsprechende Eingaben (zum Beispiel Problem oder Ziel) textuell im TAS festhalten können. Zur Unterstützung können Vorschläge unterbreitet werden. Weiterhin sollten Entwickler eines TAS Unternehmenskennzahlen vorschlagen, durch die Nutzer später den Erfolg eines ML-Projekts ermitteln können. Für die Instandhaltung liefert beispielsweise die DIN EN 15341 (Deutsches Institut für Normung 2022) Vorschläge. Im Anschluss gilt es, ein geeignetes Projektteam zu spezifizieren, welches interdisziplinär aufgebaut sein sollte und über die Vorkenntnisse verfügt, um sich am Projekt zu beteiligen.

- 1. Integration eines Beschreibungsansatzes zum Festhalten des Projektziels**
 - a. Verwenden von Textfeldern
 - b. Insofern möglich: Vorbereiten von Vorschlägen
- 2. Präsentation von Vorschlägen für Unternehmenskennzahlen, zum Beispiel:**
 - a. Jahresgesamtkosten eines Bereichs
 - b. Nichtverfügbarkeitskosten von Anlagen
 - c. Kosten von Ersatzteilen
 - d. Häufigkeit von durchzuführenden Eingriffen
- 3. Entwicklung eines Ansatzes zur Spezifikation eines Projektteams**
 - a. Domänenexpertise
 - b. Informationstechnik
 - c. Projektsponsor
 - d. Datenkompetenz

Beschreibung der technischen Infrastruktur

Zur Anleitung der Nutzer eines TAS ist in diesem Schritt eine systematische Vorgehensweise zu wählen. Hierfür bietet das dreistufige Modell in Abbildung 31, welches für diese Arbeit entwickelt wurde, einen Ansatz. Dieses untergliedert Netzwerkarchitekturen in eine Sensorschicht und eine Netzwerkschicht. Die Sensorschicht kann zudem weiter in die Datenerfassung und die Kommunikation untergliedert werden.




Abbildung 31: Vorgehen zur Konzeptionierung der Netzwerkinfrastruktur, eigene Darstellung in Anlehnung an Molano et al. (2018)

Im Zuge der anfänglichen *Datenerfassung* sind seitens der Nutzer zunächst die verwendeten Sensoren zu spezifizieren. Hierzu werden für den betrachteten Anwendungsfall relevante Sensoren ausgewählt und charakterisiert. In ihrer Literaturrecherche ermitteln Samatas et al. (2021), dass beispielsweise für Instandhaltungsmaßnahmen in der Produktion Temperatur-, Schwingungs-, Lärm- und Akustiksensoren verwendet werden (siehe auch Abbildung 32). Da Daten nicht kontinuierlich gewinnbringend aufgenommen werden

können, bedarf es anschließend eines Aktivierungskriteriums (auch Trigger genannt). Dieses legt fest, wann eine Aufzeichnung beginnt. (Kreutzer 2023) Mögliche Triggersignale sind Signale aus Maschinenprogrammen, Stromaufnahmen von Antrieben, Kraftsignale oder Temperatursignale. Diese lassen sich dabei oftmals als binäre Werte oder ganzzahlige Werte beschreiben. (Beiß et al. 2024)

Die *Kommunikationsebene* befasst sich daraufhin mit der Anbindung an die Netzwerkinfrastruktur. In diesem Zuge gilt es, den Weitertransport aufgenommener Daten mittels Busprotokollen zu definieren. Hierzu ist zunächst sensorspezifisch darzulegen, ob Signale analog oder digital aufgezeichnet werden. Anschließend ist der Datentyp festzulegen. Datentypen in der Produktion lassen sich dabei unter anderem in Zeichenketten, Binäre Werte, Dezimalzahlen, Fließkommazahlen oder Zeitstempel unterteilen (Bodendorf 2006). Daran anknüpfend sind Busprotokolle zu definieren, welche zur Kommunikation zwischen Sensoren und der speicherprogrammierbaren Steuerung dienen. Übliche, in der Industrie verbreitete Systeme, sind unter anderem Profinet, Profibus, Powerlink, Modbus sowie MeterBus (Senna et al. 2020; Liu et al. 2018) Daraufhin ist ein Netzwerkprotokoll zu definieren. Etablierte Protokolle dazu sind unter anderem der Message Queuing Telemetry Transport (MQTT), die Open Platform Communications Unified Architecture (OPC UA), MTConnect oder Ethernet (Hardt et al. 2024; Farooqui et al. 2019; Babel 2023). Eigenschaften zu den Busprotokollen sowie den Netzwerkprotokollen finden sich in Anhang A6. Die Tabellen darin fungieren als Entscheidungsunterstützung. Letztlich ist die Aufzeichnungsfrequenz je Sensor darzulegen.

Die *Netzwerkschicht* letztlich wird durch die *Netzwerktechnologie* ausgeprägt. Auf dieser ist eine Beschreibung der Datenspeicherung notwendig. Hierzu eignen sich entweder unternehmensinterne Datenbanken oder externe Cloud-Services. Etablierte Lösungen für Cloud-Services für die Produktion sind unter anderem Amazon Web Services, Microsoft Azure, IBM Smart Cloud Enterprise oder Google App/Compute Engine (Krüger et al. 2017).

Die folgende Auflistung zeigt eine strukturierte Anwendung des Vorgehens auf.

1. Betrachtung der Sensorschicht

- a. Umsetzung der Datenerfassung
 - i. Auswahl geeigneter Sensoren zur Aufnahme von Produktionsdaten
 - ii. Definition eines Triggersignals zur Identifikation produktiv nutzbarer Daten
- b. Umsetzung der Kommunikationsebene
 - i. Ansätze zur Spezifikation des Datenformats
 - ii. Ansätze zur Festlegung des Datentyps
 - iii. Maßnahmen zur Angabe der Abtastrate je Sensor
 - iv. Ansätze zur Beschreibung des Busprotokolls
 - v. Definition eines möglichen Netzwerkprotokolls

2. Betrachtung der Netzwerkschicht

- a. Umsetzung der Netzwerktechnologie: Festlegung von Maßnahmen zur Speicherung der aufgezeichneten Daten
 - i. Interne Datenbank
 - ii. Externe Cloud-Services

Datenaufnahme

Mit Hinblick auf IA 6 bedarf es weiterführender Erläuterungen für Nutzer, sodass diese Datenintegrität sicherstellen können. Hierzu ist auf eine geeignete Beschreibung mit Hinweisen für eine hohe Datenqualität zu achten. So sollten Daten repräsentativ und somit sinnvoll für den Anwendungsfall sein. Hingegen dürfen sie keine statistischen Verzerrungen aufweisen. Auch muss Konsistenz zwischen Daten bestehen. Demnach sind Widersprüche und Mehrdeutigkeiten zwischen verschiedenen implementierten Sensoren zu verhindern. Drittens ist auf ausreichende Genauigkeit zu achten. Demzufolge dürfen Daten keine Fehler enthalten, also nicht unvollständig sein oder unklare Ausreißer enthalten. Alle enthaltenen statistischen Unsicherheiten sind hingegen bekannt. Letztlich sind die Daten interpretierbar und folglich kausal mit Hinblick auf Vorkommnisse in der Produktion erklärbar. (Mockenhaupt 2021)

Im Anschluss sind Vorschläge zur Selektion von möglichen Signalen zu geben. In Anlehnung an Jardine et al. (2006) lassen sich Produktionsdaten in einzelne zu bestimmten Zeitpunkten aufgenommene Messwerte, wellenförmige Messwerte aus einer Messreihe und mehrdimensionale Messwerte unterscheiden. Zu den ersten beiden Kategorien zählen exemplarisch Vibrations-, Akustik- oder Temperaturaufnahmen, sowie Leistungsaufnahmen oder die Überwachung von Drücken oder Ölzuständen. Wichtige Vertreter von mehrdimensionalen Messdaten sind Bilder und Thermographie- oder Röntgenaufnahmen von Bauteilen. Einen Überblick über mögliche Produktionsdaten gibt Abbildung 32.




Abbildung 32: Mögliche Produktionsdaten, eigene Darstellung in Anlehnung an Jardine et al. (2006)

Das Vorgehen zur Realisierung der Datenaufnahme lässt sich in Anlehnung an Mockenhaupt (2021) wie folgt beschreiben:

1. Sicherstellung von Datenintegrität

- a. Beschreibt Maßnahmen zur Verhinderung von Fehlern in Daten

- b. Umfasst qualitative Aspekte und Zuverlässigkeit der Daten

2. Anforderungen an hohe Datenqualität sicherstellen

- a. Repräsentativität
- b. Konsistenz
- c. Genauigkeit
- d. Interpretierbarkeit

Datenbewertung

Ein Vorgehen zur Entwicklung der Datenbewertung setzt sich aus zwei übergeordneten Instrumenten zusammen. Zur explorativen Analyse sind einerseits verschiedene Methoden der deskriptiven Statistik zu integrieren. So erlauben Lagemaße die Ermittlung von Tendenzen in den betrachteten Daten (Kosfeld et al. 2016a). Klassische Vertreter sind nach Auffassung der Autoren unter anderem Modus, Median sowie arithmetisches, geometrisches oder harmonisches Mittel. Weiterhin sollten Streuungsmaße angegeben werden, da diese die Verteilung der Daten besser repräsentieren (Kosfeld et al. 2016b). Hierzu eignen sich beispielsweise Spannweite, Quartilsabstand, mittlere absolute Abweichung oder Standardabweichung sowie die Varianz. Andererseits sind weiterführende Untersuchungen mittels verschiedener grafischer Darstellungen vorzunehmen (Planing 2022). Gemäß dem Autor sind für Zeitreihen in diesem Zusammenhang unter anderem Tabellen (Häufigkeitstabellen, Kreuztabellen) sowie verschiedene Diagramme (Linien-, Streu-, Kreis-, Fehlerbalken-, Säulendiagramme sowie Boxplots, Histogramme) zu verwenden. Die folgende Tabelle kann in diesem Zusammenhang Unterstützung bei der Auswahl von geeigneten Diagrammen liefern.

Tabelle 13: Übersicht über verschiedene mögliche Diagramme, eigene Darstellung in Anlehnung an Planing (2022), Kosfeld (2016)¹⁷ und Bilogur (2018)

Diagrammart	Einsatzbereich	Anzahl Variablen	Datenart	Vorteile	Nachteile
Säulendiagramm	Häufigkeiten	1	Qualitative Daten	Visualisierung für Zeitreihen	Eingeschränkt für kontinuierliche Daten
Kreisdiagramm	Häufigkeiten	1	Qualitative Daten	Lesbarkeit, ideal für Verhältniswerte	Vergleichbarkeit bei vielen Variablen
Gestapeltes Säulendiagramm	Häufigkeiten	>1	Qualitative Daten	Eignung für mehrere Variablen	Übersichtlichkeit bei kleinen Verhältnissen
Boxplot	Zentrale Tendenzen	Beliebig	Metrische Daten	Integriert verschiedene Lagemaße	Nicht intuitiv

¹⁷ (Kosfeld et al. 2016b), (Kosfeld et al. 2016c), (Kosfeld et al. 2016d).

Diagrammart	Einsatzbereich	Anzahl Variablen	Datenart	Vorteile	Nachteile
Histogramm	Zentrale Tendenzen	1	Metrische Daten	Zeigt Verteilungsmuster deutlich	Balkenbreite beeinflusst Interpretation
Fehlerbalkendiagramm	Zentrale Tendenzen	Beliebig	Metrische Daten	Übersichtlichkeit	Fehlerbreite nicht eindeutig definiert
Streudiagramm	Zusammenhänge	>1	Metrische Daten	Zeigt Zusammenhänge, Cluster und Ausreißer	Lesbarkeit bei nah beieinander liegenden Datenpunkten

1. Integration von Werkzeugen der deskriptiven Statistik

- Lagemaße: Modus, Median, arithmetisches, geometrisches oder harmonisches Mittel
- Streuungsmaße: Spannweite, Quartilsabstand, mittlere absolute Abweichung Standardabweichung, Varianz

2. Integration von grafischen Darstellungen

- Verwendung von Tabellen
- Verwendung von Diagrammen

Datenvorbereitung

In ihrer Arbeit visualisieren Pavlič et al. (2022) einen Prozess zur Datenvorbereitung bestehend aus den beiden übergeordneten Schritten *Datenverarbeitung* und *Merkmalsextraktion*. In Anlehnung an dieses wird für diese Arbeit ein Ansatz entwickelt, durch den integrierte Daten sinnvoll vorverarbeitet werden können. Dieser ist in Abbildung 33 visualisiert und findet Eingang in das Vorgehen unten.




Abbildung 33: Vorgehen zur Datenvorbereitung, eigene Darstellung in Anlehnung an Pavlič et al. (2022)

Entsprechend des Vorgehens bedarf es im Zuge der *Datenverarbeitung* zunächst einer Möglichkeit zur *Auswahl der relevanten Daten*. Dazu sind solche Sensorsignale zu entfernen, welche mit Hinblick auf Domänenwissen keinen Mehrwert erwarten lassen. Im Anschluss ist eine *Bereinigung der Daten* durchzuführen. Hierbei sind fehlende Werte innerhalb des Datensatzes zu löschen. Weiterhin ist das Filtern ausgewählter Sensordaten auf relevante Merkmalsbereiche vorzunehmen sowie nicht relevante Daten zu entfernen.

Anschließend bedarf es Techniken zur *Erweiterung der Daten*. Hierzu sind insbesondere für Anwendungen des Supervised Learnings einige spezifische Schritte zu beachten. Da im Kontext der Anwendung in Produktionsumgebungen davon auszugehen ist, dass es sich bei aufgenommenen Daten um ungelabelte Daten handelt, ist zunächst das Hinzufügen von Labels zu den Daten vonnöten. Darüber hinaus können weiterführende Informationen durch die Generierung statistischer Merkmale gewonnen werden. Als solche lassen sich Merkmale im Zeit-Bereich, Frequenz-Bereich und Zeit-Frequenz-Bereich unterscheiden (Delgado et al. 2011) (siehe auch Abbildung 34). Anschließend ist eine Normalisierung oder alternativ eine Standardisierung durchzuführen. Hierbei ist insbesondere die sogenannte Min-Max-Normalisierung gebräuchlich (Goldstein und Uchida 2016). Eine Min-Max-Normalisierung kommt dann zum Einsatz, wenn keine Informationen über die Verteilung der Merkmale vorliegen, während eine Z-Score Standardisierung nur zum Einsatz kommen sollte, wenn die Merkmale normalverteilt sind (Effrosynidis 2020).




Abbildung 34: Mögliche statistische Merkmale für Zeitreihen, eigene Darstellung in Anlehnung an Delgado et al. (2011) und Preusche (2018)

Im Rahmen der *Merkmalsgenerierung* sind letztlich diejenigen Merkmale auszuwählen, die später zum Trainieren des ML-Algorithmus genutzt werden. In diesem Zusammenhang lassen sich zwei Ansätze unterscheiden (Alpaydın 2022). Die Merkmalsselektion identifiziert zunächst jene Merkmale, welche die meisten Informationen enthalten. Hierzu sind Techniken wie unter anderem Analysis of Variances (ANOVA) F-Score, Mutual Information, Least Absolute Shrinkage and Selection Operators (LASSO) und Random Forest Klassifikationen in ein TAS zu integrieren (Theng und Bhoyar 2024). Bei der anschließenden Merkmalsextraktion werden aus einer Kombination der bestehenden Merkmale neue generiert. Hierbei sollten die sogenannte Principal Component Analysis (Maćkiewicz und Ratajczak 1993), die Linear Discriminant Analysis (LDA) und die Factor Analysis (van Tran und Yang 2012) integriert werden sowie weitere Techniken, welche Theng und Bhoyar (2024) beschreiben. Anhang A7 vergleicht die Methoden miteinander und fungiert als Entscheidungsunterstützung.

Im Falle der Merkmalsselektion sind zwei Subschritte vorzunehmen: zunächst sollten die statistischen und realen Merkmale algorithmusbasiert vorselektiert werden (siehe Vorgehen oben). Im zweiten Subschritt kann eine domänenspezifische Überprüfung durch

Anwender erfolgen. Abhängig ihrer Fähigkeiten können diese die vorselektierten Merkmale unter Umständen in Bezug auf ihre Praxistauglichkeit bewerten.

1. Realisierung von Maßnahmen zur Datenverarbeitung

- a. Auswahl der relevanten Sensorsignale aus Praxisperspektive
- b. Bereinigung der Daten
 - i. Löschen fehlender Werte
 - ii. Filtern der Sensordaten auf relevanten Merkmalsbereich (entlang y-Achse)
 - iii. Löschen nicht relevanter Daten (entlang x-Achse)
- c. Erweiterung aufgenommener Daten
 - i. Bei Supervised Learning: Hinzufügen von Labels zu den Daten
 - ii. Normalisierung der Daten: Standardisierung oder Min-Max Normalisierung
 - iii. Berechnung statistischer Kennwerte zur Identifikation weiterführender Erkenntnisse

2. Implementierung von Maßnahmen für die Merkmalsgenerierung

- a. Extraktion und Selektion von Merkmalen
 - i. Implementierung von Techniken zur Merkmalsselektion
 - ii. Implementierung von Techniken zur Merkmalsextraktion
- b. Definition einer Menge finaler Merkmale
 - i. Algorithmusbasierte Vorselektion
 - ii. Feinselektion auf Grundlage von Domänenwissen

Algorithmeinsatz

Als Grundlage ist zunächst eine Aufteilung des Datensatzes in einen Trainings- und einen Testdatensatz vonnöten. Üblicherweise wird dazu ein sogenanntes Trainings-Test-Verhältnis zwischen 70:30 und 80:20 gewählt (Gholamy et al. 2018).

Daraufhin gilt es, sich mit der Auswahl eines Algorithmus zu befassen. Übliche Algorithmen sowohl für das Supervised Learning als auch das Unsupervised Learning wurden in Abschnitt 2.1.1 vorgestellt. Mit Hinblick auf das sogenannte No-Free-Lunch-Theorem (Wolpert 1996) sollten in diesem Zusammenhang verschiedene Algorithmen zur Verfügung stehen. Dem Theorem zufolge eignen sich einzelne Algorithmen immer nur für spezifische Datensätze und liefern keine global beste Lösung (Alpaydın 2022). Im Anschluss bedarf es Leistungsmetriken zur Evaluation der Algorithmen. Üblicherweise werden hierfür die in 2.1.1 angeführten Metriken verwendet.

1. Aufteilung in Trainings- und Testdatensatz**2. Implementierung von verschiedenen Algorithmen**

- a. Supervised Learning: Klassifikatoren und Regressionsmodelle
- b. Unsupervised Learning: Mustererkennung

3. Evaluation der Algorithmen mittels Leistungsmetriken

- a. Klassifikation: Konfusionsmatrix, Receiver Operating Characteristics
- b. Regression: Fehlermetriken
- c. Unsupervised Learning: Abstandsmetriken

Evaluation der Ergebnisse

Zu diesem Zweck sollte den Nutzern eines TAS Möglichkeiten an die Hand gegeben werden, durch die sie die erzielten Ergebnisse mit den entsprechenden zuvor getätigten Eingaben abgleichen können. Exemplarisch können hierzu Inhalte aus vorgelagerten Prozessmodellschritten wiederholt werden.

5.3.3.2 Sicherstellen von Lernförderlichkeit

Ein lernförderliches TAS sollte derart gestaltet sein, dass es *ganzheitliche* oder *vollständige Aufträge* umfasst. Ein weiterer wichtiger Aspekt ist die Vielfalt der *Teiltätigkeiten* innerhalb einer Aufgabe. Die beiden Kriterien lassen sich durch die Verwendung eines vollständigen Prozessmodells mit allen darin enthaltenden Schritten umsetzen. Darüber hinaus sollten die Nutzer eines TAS *Entscheidungsspielraum* in der Ausführung ihrer Tätigkeiten haben. Zur Realisierung bedarf es daher unterstützender Maßnahmen, sodass Kommunikation im Projektteam gefördert wird sowie zum Ausprobieren verschiedener Techniken im Zuge der Datenvorbereitung und Algorithmuswahl. Kritisch zu überlegen ist, ob AutoML verwendet werden sollte. Ein weiteres zentrales Kriterium sind Maßnahmen zur *Reflexion*. Diese beinhalten strukturelle Reflexion durch Rückblicke auf einen abgeschlossenen Prozessmodellschritt sowie Selbstreflexion, bei der neue Ergebnisse mit früheren Eingaben verglichen werden. Schließlich muss ein TAS individuell auf die *Kompetenzen der Lerner* abgestimmt sein. Beispielsweise sind Programmieraufgaben auszuschließen, wenn die Lernenden über keine entsprechenden Vorkenntnisse verfügen.

1. Betrachtung eines vollständigen Auftrags

- a. Integration eines vollständigen ML-Projekts

2. Unterteilung des Auftrags in unterschiedliche Teiltätigkeiten

- a. Integration sämtlicher Prozessmodellschritte

3. Gewährleistung von Entscheidungsspielraum

- a. Maßnahmen zur Unterstützung von interdisziplinärer Kommunikation
- b. Maßnahmen zum Ausprobieren verschiedener Datenvorbereitungsschritte und ML-Algorithmen
- c. Entscheidung über Verwendung von AutoML

4. Integration von Maßnahmen zur Reflexion

- a. Strukturelle Reflexion
- b. Selbstreflexion

5. Fokussierung auf tatsächliche Kompetenzen der Lerner

- a. Außen vor lassen von Inhalten, welche für Zielgruppe nicht notwendig sind.

5.3.3.3 Konstruktion des Datenmanagements

Für die Auswahl einer geeigneten Datenbank sind vier Aspekte zu berücksichtigen. Zunächst ist zu überlegen, welche Relevanz die Ziele von Datenbanken haben. Diese untergliedern sich gemäß Abschnitt 4.5.3.3 in eine strukturierte Speicherung, die Verwaltung von Nutzergruppen und in die Datennutzung im Unternehmen. Anschließend bedarf es einer Entscheidung, ob eine kommerzielle oder eine nicht-kommerzielle Datenbank verwendet wird. Zudem ist zu definieren, welches Datenformat gewählt wird. Klassische Vertreter sind CSV, JSON und XML. Letztlich muss entschieden werden, ob auf das Konzept der Serialisierung gesetzt wird, um Daten unabhängig der Programmiersprache und netzwerkübergreifend zu speichern. Eine Entscheidungsunterstützung zur Auswahl einer Datenbank und zum Datenformat bieten die Tabellen in Anhang A8.

1. Entscheidung über Relevanz der Ziele von Datenbanken

- a. Strukturierte Speicherung
 - i. Strukturiert: Relationale Datenbank, Zeitreihendatenbank, In-Memory-Datenbanken, Data Warehouses
 - ii. Unstrukturiert: NoSQL-Datenbank, Objektorientierte Datenbank
- b. Verwaltung der Nutzerzugriffe
 - i. Leichte Unterscheidung: Relationale Datenbank, Data Warehouses
 - ii. Mittelschwere Unterscheidung: NoSQL-Datenbank, Zeitreihendatenbank, Objektorientierte Datenbank
 - iii. Schwere Unterscheidung: In-Memory-Datenbank
- c. Nutzung der Daten
 - i. Leichte Nutzung: NoSQL-Datenbank, In-Memory-Datenbank, Zeitreihendatenbank
 - ii. Mittel: Relationale Datenbank, Data Warehouses
 - iii. Schwierig: Objektorientierte Datenbank

2. Entscheidung über Kommerzialisierung der Datenbank

- a. Kommerzielle Lösungen: Couchbase, SAP HANA, Amazon Redshift, Google BigQuery
- b. Nicht-kommerzielle Lösungen: PostgreSQL, MariaDB, CouchDB, Apache Derby, OpenTSDB
- c. Kommerziell und nicht-kommerzielle Lösungen: MySQL, MongoDB, InfluxDB

3. Entscheidung über ein geeignetes Datenformat, unter anderem

- a. CSV
- b. JSON
- c. XML

4. Entscheidung über Verwendung von Datenserialisierung

- a. Vorteile: Programmiersprachenunabhängige, netzwerkübergreifende und sichere Speicherung möglich
- b. Nachteile: Höherer Leistungsaufwand durch größere Dateien

5.3.3.4 Entwickeln der menschenzentrierten Oberfläche

Zur Umsetzung des Gestaltungsmodells bedarf es im nächsten Schritt der Entwicklung einer *menschenzentrierten Benutzeroberfläche*. In diesem Zusammenhang ist basierend auf der Einstufung der Gestaltungsprinzipien in das Kano-Modell ein Schwerpunkt zu legen (siehe Abschnitt 4.5.3.2). In der praktischen Realisierung erfolgt zunächst eine Betrachtung von Basismerkmalen, gefolgt von den Leistungsmerkmalen und den Begeisterungsmerkmalen (siehe Abbildung 35). Die unerheblichen Merkmale werden außen vor gelassen. Eine Ausnahme bilden jene, welche Lernansätze betreffen. Diese werden im Kontext der *Exposition* adressiert (siehe Abschnitt 5.3.3.5).




Abbildung 35: Reihenfolge bei der Umsetzung von Merkmalen

Demnach sind zunächst die Basismerkmale zu adressieren. Dies umfasst das Rückgängigmachen von Eingaben, das Abfangen fehlerhafter Eingaben und die Verwendung einer einfachen Sprache. Im Anschluss ist auf die Leistungsmerkmale einzugehen. Hierbei sind acht Aspekte zu tangieren, wie unter anderem das Automatisieren möglichst vieler Aufgaben, der Gestaltung einer optisch ansprechenden Visualisierung und dem Hervorheben von Textfeldern. Letztlich sind die Begeisterungsmerkmale zu realisieren. Darunter fällt die Gestaltung einer schlanken Darstellung, der Anzeige verständlicher Fehlertexte beziehungsweise Vorschläge zur Fehlerkorrektur, eine Rückmeldung über getätigte Eingaben und Maßnahmen zum Verschieben von Fehlerkorrekturen. Auf eine ausführliche Erläuterung der einzelnen Schritte wird hier verzichtet und vielmehr auf Abschnitt 4.5.3.2 verwiesen.

1. Umsetzung von Basismerkmalen

- a. Einfache Sprache
- b. Rückgängigmachen von Eingaben
- c. Abfangen fehlerhafter Eingabe

2. Umsetzung von Leistungsmerkmalen

- a. Maßnahmen für das problemfreie Ausprobieren und Abändern
- b. Automatisierung möglichst vieler Aufgaben
- c. Ansätze für eine automatische Speicherung
- d. Gestaltung einer optisch ansprechenden Visualisierung
- e. Hervorheben von Textfeldern
- f. Anzeige fehlerhafter Eingaben
- g. Maßnahmen zur Bestätigung erfolgreicher Eingabe

- h. Ansätze für das Wiederaufgreifen zu einem späteren Zeitpunkt

3. Umsetzung von Begeisterungsmerkmalen

- a. Präsentation des Inhalts in verschiedenen Sprachen
- b. Gestaltung einer schlanken Darstellung der GUI
- c. Kurzvorstellung des aktuellen Schritts
- d. Geeignete Visualisierung des aktuellen Schritts
- e. Anzeige verständlicher Fehlertexte und Vorschläge zur Fehlerkorrektur
- f. Rückmeldungen über getätigte Eingaben
- g. Maßnahmen zum Verschieben von Fehlerkorrekturen
- h. Ansätze zum Wiederaufgreifen von Eingaben in einem zweiten Anwendungsfall
- i. Ansätze zum Einreichen von Verbesserungsvorschlägen.

5.3.3.5 Auswahl von Expositionsmaterialien

Im letzten Entwicklungsschritt bedarf es der Integration von Materialien zur *Exposition*. Hierzu stehen einerseits analoge Ansätze (Printmedien) und andererseits digitale Ansätze (E-books, MOOC, Podcasts, Videos) zur Verfügung. Digitale Medien bieten dabei Vorteile hinsichtlich Interaktionen und Flexibilisierung. Analoge Medien hingegen verringern das Risiko der Ablenkung vom Lernen. Zudem ist zu entscheiden, ob eine Kombination mehrerer Medien sinnvoll ist, beispielsweise um Vorteile beider Ansätze zu vereinen. Im letzten Schritt ist zu definieren, in welcher Reihenfolge Medien angezeigt werden sollen. Anknüpfungspunkte hierfür liefern die Verfahren Problem-Pull, Theory-Push und Reflexion-First (siehe Abschnitt 2.2.3). Somit sind in diesem Zusammenhang folgende Entscheidungen zu treffen:

1. Entscheidung über Verwendung analoger oder digitaler Medien

- a. Digital: Bei interaktivem und flexiblem Lernen
- b. Analog: Für ablenkungsfreieres Lernen

2. Entscheidung über Kombination mehrerer Medien

3. Entscheidung über Einordnung der Medien

- a. Problem-Pull
- b. Theory-Push
- c. Reflexion-First

5.3.4 Evaluieren der Gestaltung

Im letzten Schritt ist das erarbeitete TAS zu evaluieren. Hierzu sind zwei Ansätze durchzuführen. Die zunächst vorzunehmende *formative* (oder gestaltende) *Evaluation* ist Gegenstand des iterativen Entwicklungsprozesses und bewertet die Erfüllung von Kriterien während der Entstehung. Blessing und Chakrabarti (2009) sprechen hierbei von der *Unterstützungsevaluation*. Im Zuge der formativen Evaluation werden entweder quantitative Daten erhoben, welche die Realisierung von definierten Zielen überprüfen oder

qualitative Daten, welche einen Fokus auf Verbesserungsmaßnahmen legen. Zu diesem Zweck sind Tests zur Gebrauchstauglichkeit durchzuführen. (Hegner 2003; Döring 2022) Exemplarische Tests sind die System Usability Scale (Brooke 1996), das Technology Acceptance Model (Davis 1989) sowie der Fragebogen innerhalb der DIN EN ISO 9241-110 (Deutsches Institut für Normung 2020).

In der konsekutiven *summativen* (oder bilanzierende) *Evaluation* werden erzielte Lösungen mit Hinblick auf erhobene Anforderungen analysiert und bewertet. Dazu kommen üblicherweise quantitative Verfahren zum Einsatz. (Döring 2022; Hegner 2003) Beispiele stellen die oben angeführten Test zur Gebrauchstauglichkeit dar. Blessing und Chakrabarti (2009) unterteilen die *summative Evaluation* weiterführend in die *Anwendungsevaluation* und die *Erfolgsevaluation*. Die *Anwendungsevaluation* stellt sicher, dass die erarbeitete Lösung zum gewünschten Zweck eingesetzt werden kann und in diesem Zuge definierte Anforderungen erfüllt werden. Der Schwerpunkt liegt dabei auf der Nutzbarkeit und Anwendbarkeit. Die *Erfolgsevaluation* erlaubt eine Validierung. Dabei wird der Nutzen der Lösung im Feld bewertet und quantitativ bewertet. Der Schwerpunkt liegt somit auf der Nützlichkeit. (Deutsches Institut für Normung 2019a)

1. Durchführung der formativen Evaluation (Unterstützungsevaluation)

- a. Erhebung quantitativer Daten: Realisierung von definierten Zielen
- b. Erhebung qualitativer Daten: Fokus auf Verbesserungsmaßnahmen

2. Durchführung der summativen Evaluation

- a. Anwendungsevaluation: Überprüfung auf Einhaltung von definierten Anforderungen
- b. Erfolgsevaluation: Überprüfung auf Erreichung von Zielen und Zweck einer erarbeiteten Lösung

5.4 Zwischenfazit und Diskussion zur Methodenentwicklung

In diesem Kapitel wurde das methodische Vorgehen zur Operationalisierung des Gestaltungsmodells vorgestellt. Als Ergebnis entsteht eine Softwarearchitektur, welche die Grundlage eines Softwaresystem darstellt. Softwarearchitekten bietet sie einen strukturierten Ansatz, wie die einzelnen Subsysteme und Komponenten zu durchlaufen sind. Die Methode basiert auf einem Ordnungsrahmen und setzt sich aus vier Phasen zusammen. Diese werden durch die einzelnen Komponenten des Gestaltungsmodells konkretisiert. Dabei ist zunächst der Gestaltungsprozess zu planen. Im Anschluss werden die Nutzungsanforderungen an die zu erarbeitende Lösung adressiert. Hierbei kommen die Voraussetzungen (*ML-Modell*, *Lernziele*, *Technologie*) des Gestaltungsmodells zum Tragen. Im nächsten Schritt werden Gestaltungslösungen erarbeitet. Die Komponenten der Subsysteme Design (*Prozessmodell*, *menschzentrierte Benutzeroberfläche* und *Datenmanagement*) sowie Didaktik (*Exposition* und *Lernförderlichkeit*) finden hierbei Anwendung. Im letzten Schritt sind erzeugte Lösungen zu evaluieren. Die Evaluation erfolgt formativ parallel zur Entwicklung sowie summativ nach Beendigung von Entwicklungstätigkeiten.

Die vorgestellte Methode sichert in der Summe die Erreichung des FTZ 2. Eine exemplarische Umsetzung der Methode legt das folgende Kapitel dar.

Wie in Abschnitt 5.2 erläutert, wurde in der Methode die Phase *Verstehen und Festlegen des Nutzungskontext* nicht betrachtet. Dies wurde damit begründet, dass in dieser Arbeit eine Fokussierung auf Prozessverantwortliche und operative Teamleiter erfolgt, welche in der Folge zu CDS ausgebildet werden. Offen ist, ob Gestaltungsmodell und Methode sich auch für andere Zielgruppen übertragen lassen. Soll das Gestaltungsmodell dahingehend angepasst werden, ließe sich eine weitere denkbare Komponente mit *Zielgruppe* betiteln. Hier könnten exemplarisch Produktionsmitarbeiter oder höhere Managementgruppen mit Aufgaben und Voraussetzungen beschrieben werden. Darüber hinaus ist in einem solchen Fall auch die Operationalisierungsmethode zu erweitern (FAM 6). Hier bietet sich ein Aufgreifen der ersten Phase *Verstehen und Festlegen des Nutzungskontexts* an. In dieser könnte die Zielgruppe charakterisiert und zu adressierende Anforderungen abgeleitet werden.

6 ANWENDUNG UND EVALUATION VON GESTALTUNGSMODELL UND METHODE

Dieses Kapitel fokussiert die Anwendung der zuvor entwickelten Inhalte. Dazu werden zwei Stoßrichtungen verfolgt. Im ersten Schritt wird das in Kapitel 4 konzipierte Gestaltungsmodell anhand der entwickelten Methode aus Kapitel 5 in eine Softwarearchitektur operationalisiert (Abschnitt 6.1). Dazu werden die einzelnen Gestaltungscomponenten strukturiert umgesetzt und von einer Unterstützungsevaluation begleitet. Im zweiten Schritt erfolgen zwei Anwendungen in Lernfabrik und industrieller Praxis (Abschnitt 6.2). Hierbei werden eine Anwendungs- und Erfolgsevaluation durchgeführt. Die Ergebnisse daraus werden in Abschnitt 6.3 erläutert und im Anschluss kritisch diskutiert (Abschnitt 6.4). Das Kapitel endet mit einer Zusammenfassung (Abschnitt 6.5).

6.1 Operationalisierung in eine Softwarearchitektur

In diesem Abschnitt wird zunächst dargelegt, wie die prototypische Umsetzung des Gestaltungsmodells erarbeitet wird. Diese hat zum Ziel, als Lösung für die spätere Anwendung in der industriellen Praxis zu fungieren. Dazu erfolgt eingangs eine Erläuterung der Entwicklungsplanung, was als essenzielle Vorarbeit in der zugrundeliegenden Norm beschrieben wird. Die Entwicklung orientiert sich dabei an den Schritten der Operationalisierungsmethode aus Abbildung 30.

6.1.1 Planen des Gestaltungsprozesses

In die Entwicklung sind gemäß der Norm Personen verschiedener Ausbildungshintergründe zu involvieren. Methodische Expertise und Fachexpertise aus dem Produktionsmanagement bringen Absolventen des Wirtschaftsingenieurswesens und Maschinenbaus in die Operationalisierung ein, welche sich darüber hinaus fachlich in der Kompetenzentwicklung vertieft haben. Hintergründe des maschinellen Lernens und des Umgangs mit Datenbankstrukturen inkludieren Verantwortliche der Informatik und des Cognitive Science. Produktionsbezogene Domänenexpertise entstammt aus Befragungen von technischem Personal. Mitarbeiter aus der Informationstechnik liefern zudem Hilfestellungen in Bezug auf darin verortete Probleme. Da keine Mitarbeiter der Arbeitswissenschaften im Projekt beteiligt sind, wird eine intensive Einarbeitung in das entsprechende Themenfeld seitens des Entwicklerteams vorgenommen, mit dem Ziel auch Anforderungen daraus sicherzustellen (siehe beispielsweise IA 2 und IA 3).

6.1.2 Festlegen der Nutzungsanforderungen

In diesem Abschnitt wird Rückgriff auf die im Gestaltungsmodell aufgestellten Componenten des Subsystems *Voraussetzungen* genommen und jeweils beschrieben, wie sie umgesetzt wurden.

6.1.2.1 Auswahl eines ML-Modells

Wie in Abschnitt 2.1.2 dargestellt, ist die Instandhaltung von Produktionsanlagen eine der Kerntätigkeiten produzierender Unternehmen, welche notwendig, jedoch nicht wertschöpfend ist. Insbesondere die Zustandsüberwachung offeriert hier die Möglichkeit, Instandhaltungskosten zu senken und die Verfügbarkeit von Anlagen zu erhöhen sowie gleichzeitig einen niederschweligen Einstieg in den Themenkomplex ML darzustellen (Elattar et al. 2016). Hierzu eignet sich vor allem die binäre Klassifikation von Maschinenzuständen, was den gebräuchlichsten Anwendungsfall darstellt (Phan et al. 2022; Cinar et al. 2022; Carvalho et al. 2019). Sie stellt darüber hinaus auch eine Grundlage für eine konsekutive Zustandsprognose dar (Preusche 2018), welche Unternehmen weitere Einsparpotenziale bietet. Mit Hinblick auf ihre praktische Relevanz erfolgt im Zuge des hier operationalisierten TAS eine Fokussierung auf die binäre Klassifikation von Maschinenzuständen. Die vorliegende Arbeit orientiert sich damit am beschriebenen Forschungsstand.

6.1.2.2 Definition von Lernzielen

Zur Definition konkreter Lernziele wird eine Kompetenztabelle erstellt. In dieser werden die Eigenschaften von CDS als Hauptkompetenzen einsortiert und jene Anforderungen an die Zielgruppe mit inhaltlicher Überschneidung zu den Eigenschaften als Teilkompetenzen zugeordnet werden (siehe auch Abschnitt 4.4.2). Darauffolgend werden diese durch entsprechende Taxonomiestufen konkretisiert. Der Fokus der Taxonomiestufen und damit der Teilkompetenzen liegt in Anlehnung an Anderson et al. (2001) auf den Stufen 2 (Verstehen) und 3 (Anwenden), da diese als besonders relevant für die Zielgruppe angesehen werden. Einzelne Kompetenzen, insbesondere jene zu den ML-Grundlagen und zum Datenverständnis, lassen sich hingegen den Stufen 1 (Erinnern), 4 (Analysieren) und 5 (Evaluieren) zuordnen. Auf Basis der Expertise des Autors dieser Arbeit werden die Teilkompetenzen anschließend durch Handlungs- und Wissens Elemente ergänzt. Hierbei wird darauf geachtet, dass Lerner ML-Konzepte sowohl wiederholen als auch in der Produktionsumgebung ihres Unternehmens anwenden können. Die in dieser Arbeit entwickelte Kompetenztabelle besteht in der Summe aus sechs Hauptkompetenzen, welche sich in insgesamt zwölf Teilkompetenzen untergliedern. Keine Berücksichtigung findet dabei das Domänenwissen, da es keinen unmittelbaren Bezug zum Thema ML aufweist. Tabelle 14 stellt einen vereinfachten Auszug aus der Kompetenztabelle dar, während Anhang A9 die vollständige Kompetenztabelle präsentiert.

Tabelle 14: Auszug aus der Kompetenztabelle

Hauptkompetenz	Teilkompetenz	Handlung	Wissen	Taxonomiestufe
Fähigkeit, Datenverläufe und	Fähigkeit, in der eigenen Produktion aufgezeichnete Daten mit Hinblick auf	Erkenntnisse aus der Bewertung von Trends können identifiziert werden, Beschreibung	Kenntnis über Instrumente der deskriptiven Statistik [PW]	Anwenden

Hauptkompetenz	Teilkompetenz	Handlung	Wissen	Taxonomiestufe
Modellergebnisse zu beurteilen	deskriptive Statistik erklären zu können	erfolgt anhand dieser Parameter	Verständnis über die Verläufe von Sensorwerten [BW]	
Fähigkeit, grundlegende ML-Modelle zu nutzen	Fähigkeit, Funktionsweise „einfacher“ ML-Algorithmen darstellen zu können	Verschiedene Algorithmen nennen Einen Algorithmus in eigenen Worten wiedergeben	Grobe Kenntnis über Vor- und Nachteile sowie Funktionsweise gebräuchlicher Algorithmen [PW]	Verstehen
Legende: BW = Begründungs-/Bezugswissen, PW = Professionswissen				

Entsprechend sind Nutzer des TAS nach dessen Verwendung in der Lage, grundlegende Begriffe des maschinellen Lernens nennen und erklären zu können. Sie sind außerdem befähigt, ML-Projekte strukturiert durchzuführen und diese zu verantworten. Dazu können sie verschiedene potenzielle Anwendungsfälle in der Produktionsumgebung ihres Unternehmens identifizieren und geeignete auswählen. Weiterhin verstehen sie, mit verschiedenen unternehmensinternen Interessenten zielorientiert über ihr Vorhaben zu diskutieren und diese, insofern benötigt, gewinnbringend in ihr Projekt einzubinden. Aufgenommene Daten können sie mit Hinblick auf die Verwendbarkeit für ein ML-Projekt analysieren und entscheiden, ob einzelne Sensorsignale einen Mehrwert stiften. Sie kennen außerdem verschiedene (einfache) Algorithmen und wissen, zumindest in grober Form, um deren Funktionsweise. Letztlich sind sie in der Lage, die Ergebnisse einzelner Algorithmen sinnvoll zu bewerten und diese zur Erreichung gestellter Ziele einzuordnen.

6.1.2.3 Wahl der Technologie

Um das Lernen am Arbeitsplatz mittels des TAS zu ermöglichen, werden im Rahmen dieser Arbeit mobile Geräte, und hier insbesondere Laptops, als gewinnbringend erachtet. Lernen kann somit zeit- und ortsunabhängig erfolgen. Den Erläuterungen von Bovenschulte (2020) folgend, findet die Interaktion mit dem System durch Tastatureingaben statt. Zudem ist davon auszugehen, dass große Datensätze vorliegen werden, was besondere Anforderungen an die Rechenleistung stellt. Das beschriebene TAS wird final in der Programmiersprache Python realisiert.

6.1.3 Erarbeiten von Gestaltungslösungen

Zur Erarbeitung von Gestaltungslösungen, wird in diesem Abschnitt detailliert auf die Subsysteme *Design* und *Didaktik* eingegangen. In der Folge wird entsprechend dargelegt, wie die einzelnen Komponenten praktisch realisiert wurden.¹⁸

¹⁸ Die erzielten Lösungen wurden durch den Autor in Rosemeyer et al. (2023) sowie bei Rosemeyer und Metternich (2024) veröffentlicht.

6.1.3.1 Auswahl eines Prozessmodells

Zur besseren Unterstützung von Nutzern des TAS wird in der vorliegenden Arbeit ein Modell benötigt, welches einen hohen Umfang an Struktur aufweist und welches Iterationen enthält. Zudem wird der Einbezug von Produktionscharakteristika als relevant eingestuft. Somit fällt die Wahl auf die DMME, welche folglich als Rahmen für das zu entwickelnde Assistenzsystem dient. Zur Umsetzung werden die Beschreibungen aus CRISP-DM und DMME verwendet. Mit Hinblick auf den avisierten Schulungscharakter werden die Prozessschritte bis einschließlich Evaluation ausdetailliert. Die beiden Schritte Technische Implementierung und Umsetzung adressieren die langfristige Nutzung im Betrieb und werden nur in kurzem Umfang aufgegriffen. Da hierauf in der Arbeit kein Fokus liegt, werden sie in der Folge nicht weiter betrachtet. Nutzer werden in dem TAS auf Basis von Fragen und Aufforderungen durch die einzelnen Prozessschritte geführt. Eine schematische Darstellung in Form eines Flussdiagramms zeigt Abbildung 36. Zur vereinfachten Darstellung wird in der Abbildung auf Entscheidungsschritte verzichtet¹⁹. Gestrichelte Linien zeigen optionale Kontrollschleifen an.




Abbildung 36: Schematische Darstellung des Assistenzsystems, eigene Darstellung in Anlehnung an Huber et al. (2018)

Die *Einleitung* bietet Nutzern einen Einblick in das Vorgehen innerhalb des TAS. So wird die DMME kurz vorgestellt und weitere Hintergrundinformationen zu ML-Projekten sowie zum Arbeiten mit dem TAS gegeben.

Im Zuge des *Geschäftsverständnis* soll seitens der Nutzer zunächst das Problem inklusive Ursache umfassend beschrieben werden. Im Anschluss wird das Geschäftsziel festgehalten und relevante Unternehmenskennzahlen, durch welche eine Verbesserung ersichtlich werden kann, definiert. Mit Hinblick auf das interdisziplinäre Arbeiten werden zuletzt zu integrierende Abteilungen festgehalten. Eine Zusammenfassung beschließt den Abschnitt. Diese kann zu externen Zwecken als Textdatei exportiert werden.

¹⁹ Das vollständige Flussdiagramm findet sich darüber hinaus bei Rosemeyer et al. (2025).

Im *Technischen Verständnis* formulieren Nutzer auf der Grundlage des *Geschäftsverständnisses* technische Ziele und beschreiben die Netzwerkinfrastruktur (siehe Abbildung 37). Zunächst erfolgt eine Spezifikation des zu betrachtenden Prozesses und des notwendigen technischen Ziels. Hierbei werden den Nutzern zur vereinfachten Arbeit Vorschläge gemacht, welche im Bedarfsfall individuell angepasst werden können. Außerdem sollen die treibenden beobachtbaren Abweichungen, sowie deren Ursachen erläutert werden. Zur Beschreibung der Netzwerkinfrastruktur wird auf die Vorgehensweise von Molano et al. (2018) (siehe Abbildung 31) zurückgegriffen. Diese wird von den Nutzern sukzessive durchlaufen. Letztlich bedarf es der Festlegung eines Triggersignals, durch welches produktiv nutzbare Daten ermittelt werden können.




Abbildung 37: Vorgehen im Technischen Verständnis

In der *Technischen Realisierung* werden Schritte durchlaufen, welche nicht unmittelbar im TAS durchzuführen sind. Der Abschnitt liefert daher lediglich Hilfestellungen, welche Tätigkeiten zu absolvieren sind. Dies umfasst Zugangsrechte auf Sensoren und Speichersysteme sowie Funktionstests. Im Anschluss daran ist zur Datenaufnahme ein optimaler Werkzeugzustand herzustellen, von dem Verschleiß erkennbar wird. Erhobene Daten können final mittels eines CSV-Imports in das TAS geladen werden.

Das *Datenverständnis* liefert verschiedene Werkzeuge zur Bewertung der aufgenommenen Daten. Hierzu werden deskriptive Auswertungen vorgenommen sowie Boxplots, Liniendiagramme, Streudiagramme und Histogramme erstellt. Da das Ziel des Schritts die Analyse der Daten und noch nicht deren Vorverarbeitung ist, werden die durch die Nutzer im TAS vorgenommenen Änderungen nicht gespeichert und beeinflussen daher die späteren Abschnitte nicht.

Die *Datenvorbereitung* orientiert sich an dem in Abbildung 33 vorgestellten Vorgehen von Pavlič et al. (2022) und wird für die Arbeiten hier entsprechend konkretisiert (siehe Abbildung 38).




Abbildung 38: Datenvorbereitung im TAS, eigene Darstellung in Anlehnung an Pavlić et al. (2022)

Demzufolge sollen Nutzer zunächst fehlende Datensatzeinträge löschen. Dies können sie entweder zeitstempelbasiert oder merkmalsweise vornehmen. Im Anschluss werden den Nutzern die Namen aller im Datensatz enthaltenen Merkmale angezeigt, aus denen sie solche auswählen sollen, die sie im vorherigen *Datenverständnis* auf Basis ihres Domänenwissens als gewinnbringend eingeordnet haben. Um die Performanz des TAS bei der Ausführung nicht zu beeinträchtigen, ist die Auswahl der Merkmale zahlenmäßig begrenzt. Im nächsten Schritt findet eine Reduktion der Daten auf den relevanten Merkmalsbereich statt. Dafür steht ein automatischer Filter zur Verfügung, der anhand des Interquartilsabstands Ausreißer aus den Daten entfernt. Insofern notwendig, sind die Ergebnisse manuell zu präzisieren. Das Labeln der Daten erfolgt im Anschluss grafisch. Auf Basis von Domänenwissen sind jene Bereiche im Datensatz zu markieren, in denen sich das Werkzeug in einem verschlissenen Zustand befindet. Im darauffolgenden Schritt haben Nutzer ein Zeitintervall zu definieren, durch welches der verschlissene Bereich um einen vorgelagerten Warnbereich ergänzt wird. Daraufhin werden die Daten normalisiert. Hierbei stehen die Min-Max-Normalisierung und die Standardisierung auf Basis des Z-Scores zur Verfügung. Da es sich bei den verwendeten Produktionsdaten um Zeitreihen handelt, werden zur Anreicherung des Datensatzes statistische Merkmale im Zeitbereich kalkuliert. Hierunter fallen exemplarisch das gleitende arithmetische Mittel, das gleitende Maximum und das gleitende Minimum. Im letzten Schritt erfolgen Merkmalsselektion und -extraktion. Hierbei werden auf Basis der in Abschnitt 5.3.3.1 vorgeschlagenen Methoden zunächst algorithmusbasiert Vorschläge für tatsächlich relevante (statistische und reale) Merkmale vorgenommen, welche im Anschluss auf Grundlage von Domänenexpertise bewertet werden müssen.

Die *Modellierung* umfasst drei Schritte (siehe Abbildung 39). Zunächst ist ein Trainings-Test-Verhältnis zu bilden. In diesem Zusammenhang wird den Nutzern umfassender Handlungsspielraum gewährt. Es werden lediglich Empfehlungen abgegeben. Im Anschluss erfolgt die Verwendung verschiedener ML-Algorithmen. Hierbei werden verschiedene Algorithmen des Supervised Learnings verwendet. Auf das Trainieren von Hyperparametern wird zum Zweck der Vereinfachung in dem TAS jedoch verzichtet. Die

Ergebnisse der letztlichen Modellevaluation werden sowohl grafisch durch Liniendiagramme als auch quantitativ durch die Leistungskennzahlen Accuracy, Precision und Recall präsentiert.



Abbildung 39: Vorgehen in der Modellierung

Die abschließende Evaluation fasst erzielte Ergebnisse der *Modellierung*, des *Geschäftsverständnis* und des *Technischen Verständnis* zusammen und stellt diese gegenüber. Anhand dieser kann entschieden werden, ob die ursprünglichen Ziele erreicht wurden.

6.1.3.2 Sicherstellen von Lernförderlichkeit

Mit dem Ziel, Nutzern des entwickelten TAS *vollständige Aufträge* zu bieten, wird ein vollständiges ML-Projekt beginnend mit Ist-Analyse und Soll-Definition bis zur Evaluation von Algorithmen durchlaufen. Unter Betrachtung der Zielstellung, dass Nutzer eine erste ML-Lösung implementieren und dabei das Lernen im Fokus steht, wird allerdings die Verstetigung im Unternehmenskontext nur rudimentär betrachtet. Dabei haben die Nutzer sämtliche relevante Schritte zu durchlaufen und somit *verschiedene Teiltätigkeiten* zu absolvieren. Obgleich gewisse Schritte automatisiert erste Vorschläge liefern, sind diese mit Hinblick auf den *Entscheidungsspielraum* durch die Nutzer individuell zu präzisieren oder zu bestätigen. Auf die Verwendung von AutoML wird im Kontrast zu zahlreichen der in Abschnitt 2.3.4 zitierten Publikationen zudem verzichtet. Außerdem werden den Nutzern Maßnahmen zur *Reflexion* geboten. So enden sämtliche der integrierten Abschnitte mit einer Zusammenfassung der Eingaben. Gleichermäßen werden an relevanten Stellen Rückblicke auf vergangene Eingaben geliefert, wodurch neue mit den bisherigen evaluiert werden können. Letztlich wird auf eine einfache Sprache geachtet (siehe Abschnitt 6.1.3.4) und keine Programmiertätigkeiten einbezogen. Somit wird die *individuelle Entwicklung* der Lerner berücksichtigt. Eine Zusammenfassung der Maßnahmen gibt Abbildung 40.

Kriterien	Sicherstellung von Lernförderlichkeit				
	Vollständige Aufträge	Verschiedene Teiltätigkeiten	Entscheidungs - spielraum	Reflexion	Individuelle Entwicklung
Praktische Umsetzung	Integration eines (vollständigen) Prozessmodells	Durchlaufen sämtlicher Schritte des Prozessmodells	Vorauswahl durch Nutzer zu bestätigen oder zu überschreiben Kein AutoML	Zusammenfassungen und Rückblicke auf vorherige Eingaben	Einfache Sprache, keine Programmier - tätigkeiten

Abbildung 40: Maßnahmen zur Erreichung von Lernförderlichkeit

6.1.3.3 Konstruktion des Datenmanagements

Mit Hinblick auf die Charakteristika von Daten in Produktionsumgebungen (siehe Abschnitt 2.1.2) wird davon ausgegangen, dass diese als ungelabelte Zeitreihe in tabellarischer Form vorliegen. Da das hier vorliegende TAS eine prototypische Lösung darstellt, werden im Kontrast zu den vergleichbaren Forschungsarbeiten keine Schnittstellen zu bestehenden Softwaresystemen entwickelt. Abhängig von der späteren Nutzung von Eingaben erfolgt die Speicherung somit entweder in relationalen Datenbanken, in Form sogenannter Pickle-Objekte oder in Form einer CSV-Datei (siehe Tabelle 15). In allen Fällen erfolgt die Speicherung lokal auf dem Computer der Nutzer. Zur Realisierung der Datenbank kommt die Pythonbibliothek TinyDB zum Einsatz. Hierin werden insbesondere solche Nutzereingaben gespeichert, welche in Form von Text, Zahlen, ausgewählten Buttons und dem Speicherort der hochgeladenen Dateien vorliegen. Im Zuge der weiteren Verarbeitung tabellarischer Daten ist die Speicherung in der Datenbank jedoch nicht möglich, weshalb hierbei je nach Lesbarkeit durch Nutzer eine Speicherung in Form eines Pickle-Objekts oder einer CSV-Datei vorgenommen wird.

Tabelle 15: Verwendete Datenbankansätze im TAS

Datenbankansatz	Verwendungszweck
Relationale Datenbank	Nutzereingaben (Texte, Zahlen, ausgewählte Buttons, Speicherort der hochgeladenen Dateien, unter anderem)
Pickle-Objekt	Verarbeitete Daten, welche nicht vom Nutzer gelesen werden müssen
TinyDB	Verarbeitete Daten, welche bei Bedarf vom Nutzer gelesen werden können

6.1.3.4 Entwickeln der menschenzentrierten Oberfläche

In diesem Abschnitt wird ausschnittsweise die Umsetzung der Merkmalstypen aus der Kano-Analyse vorgestellt. Die unerheblichen Merkmale werden dabei mit Ausnahme der didaktischen Aspekte (siehe Abschnitt 6.1.3.5) nicht umgesetzt.

Basismerkmale

Zunächst wird eine lineare Undo-Funktion implementiert. Weiterhin wird eine Redo-Funktion integriert, durch welche Nutzer rückgängig gemachte Eingaben

wiederherstellen können. Außerdem werden Maßnahmen zur Verhinderung zu vieler oder zu weniger Eingaben getroffen. Beispielsweise sollen Nutzer im Zuge der Datenvorbereitung solche Sensorsignale auswählen, welche sie im Zusammenhang des Datenverständnisses als relevant eingestuft haben. Mit Rücksicht auf die Prozessorleistung ist die Anzahl auf sechs Signale begrenzt. Auch eine zahlenmäßige Abweichung nach unten wird an relevanten Stellen verhindert. Exemplarisch wird von den Nutzern gefordert, dass sie mindestens zwei Bereiche mit Werkzeugverschleiß in den Sensordaten markieren. Andernfalls kann der spätere Algorithmus keine zuverlässige Klassifikation erstellen. Eine einfache Sprache in dem TAS wird derart umgesetzt, dass nach Möglichkeit keine Fachtermini verwendet werden. Außerdem werden die Formulierungen auf ein Minimum reduziert, um eine kognitive Überforderung aufseiten der Nutzer zu vermeiden.

Leistungsmerkmale

Automatisierungsschritte werden im TAS insbesondere in der Datenvorbereitung vorgenommen. So werden exemplarisch automatisiert fehlende Werte gelöscht und eine Ausreißerentfernung auf Basis des Interquartilsabstands durchgeführt. Damit Nutzer die Kontrolle über das Vorgehen behalten, müssen sie das Löschen anschließend bestätigen. Außerdem werden automatisiert statistische Merkmale berechnet und eine Normalisierung der Daten vorgenommen sowie die relevantesten Merkmale ermittelt. An der Logik der DMME orientierend ist das Springen in einen vorherigen Prozessmodellschritt jederzeit möglich. Insofern ausprobierte Eingaben seitens der Nutzer als nicht zielführend eingestuft werden, können diese auf einfache Weise angepasst werden. Zu jedem Zeitpunkt kann letztlich die Arbeit unterbrochen und zu einem späteren Zeitpunkt fortgesetzt werden. Hierbei wird jeweils auf die erste Seite eines Prozessmodellschritts gesprungen.

Begeisterungsmerkmale

Zur Verhinderung von Ablenkung wird im vorliegenden TAS mit Textmarkierungen gearbeitet, welche eine unterschiedliche Relevanz von Texten anzeigen. Als geeignete Sprachen werden Deutsch und Englisch identifiziert. Deutsch stellt die Erstsprache der meisten avisierten Nutzer dar. Englisch hingegen korrespondiert mit flankierenden Forschungsprojekten, in denen das TAS zum Einsatz kommt. Zur Realisierung klarer Fehlertexte wird ein Verweis auf die Fehlerquelle gegeben. Hierbei werden alle verwendeten Buttons und Eingabefelder mit sprechenden Namen versehen, auf die referenziert werden kann. Ansprechende Dialogfenster weisen dann in freundlicher Sprache auf den Fehler hin. Um das Wiederaufgreifen in einem zweiten Anwendungsfall zu realisieren, wird eine Speicher- und Öffnen-Funktion implementiert. Somit können Nutzer bestehende Projekte bei späterem Bedarf aufgreifen und an den entsprechenden Stellen adaptieren. Mit dem Ziel, Nutzern Orientierung über den Fortschritt zu dem aktuellen Stand zu geben, wird eine Übersichtsgrafik auf Grundlage der DMME in die GUI aufgenommen. Der aktuell bearbeitete Abschnitt wird dabei farblich markiert. Außerdem weist eine Breadcumb-Anzeige Nutzer auf den aktuellen Schritt hin.

Die GUI wird letztlich mittels der Pythonbibliothek PyQt5 praktisch umgesetzt (siehe Abbildung 43). Elemente auf der GUI lassen sich dabei in statische und dynamische Elemente unterteilen. Statische Elemente sind solche, die sich unabhängig der Nutzereingaben nicht verändern. Die Erstellung dieser erfolgt im Zuge der Entwicklung in der Software Qt Designer. Dynamische Elemente hingegen werden abhängig vom aktuellen Fortschritt angezeigt oder versteckt. Für die GUI werden sie unmittelbar in Python programmiert.

6.1.3.5 Auswahl von Expositionsmaterialien

Mit dem Ziel, Nutzern die Vermittlung von deklarativem Wissen zu ermöglichen, wird im vorliegenden TAS auf internetbasierte Lerninhalte gesetzt, welche in vorherigen Forschungsprojekten unter Mitarbeit des Autors dieser Arbeit entwickelt wurden (Bardy et al. 2021; Rosemeyer et al. 2022). Nutzer können diese abhängig ihrer Vorkenntnisse kostenfrei und flexibel aufrufen. Ob diese, andere Quellen oder überhaupt keine verwendet werden, obliegt mit Hinblick auf ihre Selbstbestimmung in der Verantwortung der Lerner. Die Inhalte werden anschließend den einzelnen Abschnitten der DMME zugeordnet, so dass Lerner sie problembezogen nutzen können. Optional besteht auch die Möglichkeit, einen gesammelten Überblick über alle integrierten Lerninhalte zu bekommen.

Um die Lernsequenzierung richtig festlegen zu können, wird zunächst eine theoretische Betrachtung vorgenommen, welcher im Anschluss eine Übertragung auf das zu entwickelnde TAS folgt.

In Abschnitt 2.2.3 wurden verschiedene Ansätze (Problem-Pull, Theory-Push, Reflexion-First) zur Lernsequenzierung erörtert und Einsatzbereiche festgehalten. Hingegen ist das AiL gekennzeichnet von informellem und non-formalem Lernen. Lernen erfolgt darin selbstbestimmt und in der selbst präferierten Geschwindigkeit. Letztlich erfolgt Lernen situativ am eigenen Arbeitsplatz. Aus dieser theoretischen Betrachtung ergeben sich drei Erkenntnisse:

- Der in den Lernkonzepten geforderte Erprobungsort ist der eigene Arbeitsplatz.
- Ob Theorieinhalte aufgenommen werden, hängt von den Vorerfahrungen und der persönlichen Einstellung der Lerner ab und kann nicht forciert werden.
- Eine Erschließung des Praxisproblems ist optional und kann nicht zwingend angenommen werden.

Auf der Grundlage dieser Erkenntnisse wird für das operationalisierte TAS entschieden, dass keines der drei vorgestellten Lernkonzepte in seiner beschriebenen Urform für das AiL geeignet ist, sondern eine Adaption notwendig ist. Da die anfängliche Erschließung des Problems durch die Nutzer nicht gewährleistet und Problem-Pull damit nicht aufgegriffen werden kann, erfolgt eine Adaption des Theory-Push. Mit Hinblick auf das optionale Durchlaufen der Exposition wird die vorgenommene Anpassung in der Folge als *Optional-Theory-Push* bezeichnet. Abbildung 41 legt den didaktischen Aufbau dar.




Abbildung 41: Didaktischer Aufbau des TAS, eigene Darstellung in Anlehnung an Glass (2021)

6.1.4 Evaluieren der Gestaltung

Die Operationalisierung des Gestaltungsmodells erfolgt final in mehreren Zyklen (siehe Abbildung 42). Am Ende eines Zyklus wird Rückmeldung von potenziellen Nutzern hinsichtlich des Mehrwerts des jeweils erzeugten Softwaresystems (*Unterstützungsevaluation*) eingeholt. Dazu wird Rückgriff auf das Technology Acceptance Model (TAM) (Davis 1989) genommen. Dieses ermittelt, wie potenzielle Nutzer ein neu entwickeltes System bewerten. Die darin erhobene wahrgenommene Nützlichkeit beschreibt, inwiefern Anwender eine Veränderung ihrer Produktivität durch die Verwendung des Systems einschätzen. Die wahrgenommene Benutzerfreundlichkeit hingegen stuft die Einfachheit der Lösungsnutzung durch Anwender ein. Beide Kriterien werden gemäß dem zitierten Autor auf einer siebenstufigen Likert-Skala bewertet.




Abbildung 42: Vorgehen zur Unterstützungsevaluation, eigene Darstellung in Anlehnung an Rosemeyer et al. (2023) und Rosemeyer und Metternich (2024)

Für die Evaluation kommt das TAS in ML-Weiterbildungen in der Prozesslernfabrik Center für industrielle Produktivität (CiP) an der Technischen Universität Darmstadt zum Einsatz. Beteiligten Lernern wird im Anschluss ein Fragebogen auf Grundlage des TAM vorgelegt. In den Nutzerstudien identifizierte Schwächen werden im folgenden Zyklus angegangen. So wird im ersten Durchgang ($n = 9$) zwar die wahrgenommene Nützlichkeit hoch bewertet (Nutzbarkeit bei der Arbeit: $\bar{x} = 5,89$, Arbeitsvereinfachung: $\bar{x} = 5,44$). Die wahrgenommene Benutzerfreundlichkeit hingegen weist Entwicklungspotenzial auf (Arbeit mit dem System: $\bar{x} = 4,78$). (Rosemeyer et al. 2023) Zu diesem Zweck werden in der zweiten Iteration vertiefende Anstrengungen in der Gestaltung der

menschzentrierten Benutzeroberfläche vorgenommen. In der konsekutiven zweiten Studie ($n = 13$) werden entsprechend das Arbeiten mit dem System ($\bar{x} = 5,23$) sowie die Verständlichkeit ($\bar{x} = 5,62$) besser bewertet.²⁰ Die darin befragten Probanden heben positiv hervor, dass die Anzahl der Fachbegriffe reduziert wurde, was das Verständnis dieser Schritte vereinfacht. Ebenso erhöht der verringerte Beschreibungsumfang ihre Zufriedenheit, da sie weniger lesen müssen. Die benötigte Zeit für die gesamte Begehung wird in Summe reduziert, was angesichts von oftmals zu beobachtendem Zeitmangel in der Industrie (siehe Abschnitt 2.2.4) besonders relevant ist. (Rosemeyer und Metternich 2024)

6.1.5 Zwischenfazit zur Entwicklung des Tutorialsystems

In diesem Abschnitt wurde eine anhand der Operationalisierungsmethode strukturierte Umsetzung des Gestaltungsmodells präsentiert. Dabei wurde auf Grundlage der einzelnen Komponenten zunächst eine Softwarearchitektur entwickelt, welche daraufhin in einer Softwareapplikation²¹ in der Programmiersprache Python realisiert wurde. Abbildung 43 zeigt abschließend exemplarisch eine Seite aus dem *Technischen Verständnis*. Begleitende Nutzerstudien stellten die wahrgenommene Nützlichkeit und Benutzerfreundlichkeit der Lösung sicher. Sie zeigen, dass die Verwendung des entwickelten TAS wie vorgesehen funktioniert und voraussichtlich einen Mehrwert für die Zielgruppe in der praktischen Anwendung erzielen wird. Die Umfragen erfolgten dabei arbeitsorientiert in Industrieworkshops. Zu überprüfen ist im nächsten Schritt, ob der vermutete Mehrwert auch im Kontext des arbeitsintegrierten Lernens realisiert werden kann.




Abbildung 43: Visualisierung des operationalisierten TAS

²⁰ Weitere Details siehe Rosemeyer und Metternich (2025).

²¹ Der gesamte Programmcode findet sich bei Rosemeyer et al. (2025).

6.2 Anwendung in der Praxis

Der erwartete Mehrwert und das Design des zuvor entwickelten und prototypisch getesteten TAS wird in diesem Abschnitt überprüft. Ziele sind somit Anwendungs- und Erfolgsevaluation. In der *Anwendungsevaluation* wird bewertet, inwiefern die inhaltlichen und formalen Anforderungen (siehe Abschnitte 4.1, 4.3.2 und 5.1) eingehalten wurden. Die *Erfolgsevaluation* betrachtet die Erzielung der Teilkompetenzen, welche mit der Entwicklung des TAS einhergehen (siehe Abschnitt 6.1.2.2). Das Ergebnis stellt die Erreichung des FTZ 3 dar.

Zur Zielerreichung wird zunächst eine methodische Einführung bezüglich des Vorgehens vorgenommen (Abschnitt 6.2.1). Die darauffolgenden Abschnitte beschreiben die darin erläuterte Vorbereitung (6.2.2) und die Durchführung (6.2.3) der Anwendung. Die Auswertung und konsekutive Diskussion erfolgen anschließend in dedizierten Abschnitten (6.3 und 6.4).

6.2.1 Methodisches Vorgehen zur Anwendung und Evaluation

Zur strukturierten Durchführung der Anwendung wird im Rahmen dieses Abschnitts auf ein Vorgehen zurückgegriffen, welches sich auf die kompetenzorientierte Evaluation von Lernszenarien konzentriert. Dieses wurde in vergleichbaren Arbeiten erfolgreich verwendet (Tisch et al. 2014; Hambach 2019) und eignet sich auch für den hier vorgenommenen Ansatz. Zur Spezifikation für die dieser Arbeit zugrundeliegende Problemstellung wird das Vorgehen gegenüber Tisch et al. (2014) und Hambach (2019) modifiziert. So werden insbesondere notwendige Schritte ergänzt sowie andere auf die Problemstellung umbenannt. Abbildung 44 zeigt das Vorgehen grafisch.




Abbildung 44: Methodisches Vorgehen bei der Anwendung, eigene Darstellung in Anlehnung an Tisch et al. (2014) und Hambach (2019)

Dieses besteht aus den drei Phasen Vorbereitung, Durchführung und Auswertung. Im Rahmen der *Vorbereitung* erfolgt zunächst eine Transformation der Handlungselemente. Dazu werden die in der Kompetenztafel enthaltenen Handlungselemente durch sogenannte Verhaltensanker konkretisiert. Verhaltensanker sind sachlich formulierte

Beschreibungen eines Verhaltens, die es Beobachtern zu beurteilen erlauben, inwiefern eine Kompetenz vorhanden ist. Dazu werden üblicherweise drei bis fünf Verhaltensanker formuliert. (Graf und Edelkraut 2016) Anschließend ist die Handlungsaufgabe zu erstellen. Zur systematischen Gestaltung lassen sich in der Literatur dazu beispielsweise die Ansätze von Glass (2021) oder Erpenbeck et al. (2016) verwenden, welche in Abschnitt 2.2.3 vorgestellt werden. Im Anschluss sind Messinstrumente auszuwählen. Einen Überblick über verschiedene Instrumente gibt Döring (2022). In der konsekutiven *Durchführung* wird zunächst festgehalten, wie die Befähiger aus dem Gestaltungsmodell (siehe Abschnitt 4.4.5) in der Praxis umgesetzt werden. Danach werden Handlungsaufgabe und Messinstrumente prototypisch vor der eigentlichen Anwendung erprobt und hinsichtlich Probleme und Verbesserungspotenziale überprüft. Der letzte Schritt der Durchführung beschreibt den Hauptteil des Vorgehens. Dabei werden die konzipierten Schulungen durchgeführt. Die *Auswertung* befasst sich schließlich mit der *Anwendungs-* und der *Erfolgsevaluation*. Dazu wird die Erreichung der Kompetenzen sowie der Einhaltung der inhaltlichen und formalen Anforderungen überprüft. Die erlangten Ergebnisse werden final kritisch diskutiert.

6.2.2 Vorbereitung der Anwendung

In der ersten Phase wird die Anwendung vorbereitet. Die folgende Beschreibung zeigt die dazu vorgenommenen Schritte auf.

6.2.2.1 Transformation von Handlungselementen

Wie dargestellt, müssen zur Überprüfung, inwiefern die in der Kompetenztabelle beschriebenen Handlungselemente durch Lerner erreicht werden, Verhaltensanker definiert werden. Dazu erfolgt eine stufenweise Unterteilung in aufsteigender Güte. Stufe V0 beschreibt eine Fehlhandlung, bei der eine Handlung nicht erkennbar ist. Die Stufen V1 respektive V2 legen dar, dass ein Verhalten geringfügig beziehungsweise weitestgehend ersichtlich ist. V3 zeigt auf, dass Handlungselemente vollumfänglich beobachtet werden können. Alle Verhaltensanker inklusive ihrer korrespondierenden Handlungselemente können in Anhang A10 eingesehen werden. Die folgende Darstellung liefert exemplarisch zwei Umsetzungen der Handlung „Erkenntnisse anhand Leistungskennzahlen faktenbasiert einordnen können“:

- V0: Teilnehmer kann Erkenntnisse nicht faktenbasiert einordnen.
- V3: Teilnehmer kann Erkenntnisse leicht und in hoher Anzahl faktenbasiert einordnen.

6.2.2.2 Erstellen der Handlungsaufgabe

Im nächsten Schritt ist die Handlungsaufgabe zu konzipieren. Nutzer des TAS sollen dabei eine erste ML-basierte Zustandsüberwachung an einem Fertigungsprozess implementieren.

Dazu wird an dieser Stelle der methodische Aufbau des Lernszenarios vorgestellt. Er orientiert sich an dem Vorgehen von Erpenbeck et al. (2016) (siehe Abschnitt 2.2.3). Aufgrund seiner inhaltlichen Nähe wird dieses als relevant angesehen und modifiziert übernommen. Die folgende Beschreibung erläutert das Vorgehen, welches zudem in Abbildung 45 zusammengefasst ist.

In der *Vorphase* erfolgen Voruntersuchungen, welche im folgenden Abschnitt 6.2.2.3 näher beschrieben werden. Das Ziel hierbei ist, den Umfang an Wissen und Handlungsfähigkeit in Bezug auf ML-Anwendungen aufseiten der Teilnehmer vor Beginn der Schulung messen zu können. Im Kontext des *Kickoffs* erfolgt ein inhaltlicher Start in das Thema. Dabei werden mit Hinblick auf FTZ 3 zwei Szenarien unterschieden. Zur Vergleichbarkeit des arbeitsintegrierten Lernens mit TAS und dem Lernen in Form einer klassischen Weiterbildung wird eine randomisierte Kontrollgruppenstudie durchgeführt. Bei dieser werden nach dem Zufallsprinzip zwei Gruppen (Experimental- und Kontrollgruppe (EG, KG)) gebildet. Diese werden mit Hinblick auf unabhängige Variablen systematisch unterschiedlich behandelt und die Auswirkungen auf abhängige Variablen untersucht. (Döring 2022) Als unabhängige Variable ist im vorliegenden Fall die Schulungsausführung anzusehen (siehe Abbildung 45). Abhängige Variablen hingegen werden in Abschnitt 6.2.2.3 erläutert. Die Entwicklung der beiden Schulungsszenarien wird im Folgenden weiterführend beleuchtet.

	Vorphase	Kickoff	Selbstlernphase	Workshop	Lernerfolgs - messung
Experimentalgruppe	Wissenstest Handlungs- beobachtung	Einführung Instandhaltungs- strategien	Projekt- bearbeitung mit TAS und Theorieinhalten	Präsentation der Projekt- ergebnisse Reflexion über Selbstlernphase Bearbeitung offener Fragen	Wissenstest Handlungs- beobachtung
Kontrollgruppe	Wissenstest Handlungs- beobachtung	Einführung Instandhaltungs- strategien Einführung maschinelles Lernen	Projekt- bearbeitung mit Code aus TAS in Jupyter Notebooks	Präsentation der Projekt- ergebnisse Reflexion über Selbstlernphase Bearbeitung offener Fragen	Wissenstest Handlungs- beobachtung

Abbildung 45: Vorgehen bei der Handlungsaufgabe, eigene Darstellung in Anlehnung an Erpenbeck et al. (2016)

Das arbeitsintegrierte Lernen setzt wie beschrieben auf das selbstbestimmte Lernen der Teilnehmer. Über den Umfang der Theorie entscheiden sie auf Grundlage ihrer Vorkenntnisse dabei weitestgehend selbst. Zu diesem Zweck wird für die Handlungsaufgabe auf das in Abschnitt 2.2.3 beschriebene Problem-Pull gesetzt. Im Rahmen des *Kickoffs* wird den Lernern der ersten Gruppe daher die spätere Problemstellung beschrieben sowie

Grundlagen zu Instandhaltungsstrategien erläutert. Außerdem erfolgt hierin eine Einführung in das TAS. In der konsekutiven *Selbstlernphase* bearbeiten die Teilnehmer anschließend die Problemstellung, bei der sie sich kontextbasiert unter Verwendung der integrierten Lernmaterialien relevantes Wissen selbstständig aneignen. Um den Transfer in den Arbeitsalltag sicherzustellen, wird dabei das Lernen am Arbeitsort favorisiert. Hingegen ist das Lernen in den hier vorgestellten Szenarien im Prozess der Arbeit nicht realistisch (siehe hierzu auch Abschnitt 2.2.2).

Im Kontrast dazu ist ein anderes Vorgehen für die zweite Gruppe notwendig, welche nach dem Aufbau klassischer Weiterbildungen arbeiten. Diese sind im Regelfall von Trainern mit didaktisch aufbereiteten Inhalten organisiert. Lernen erfolgt dabei fremdgesteuert durch klare zeitliche Vorgaben, welche die Trainer festlegen. Das gelehrt Curriculum ist zumeist starr über die Zeit. (Erpenbeck und Sauter 2013) Entsprechend wird für die zweite Gruppe ein Ablauf nach Theory-Push gewählt. Dazu werden im *Kickoff* Instandhaltungsstrategien und Grundlagen von ML-Anwendungen vermittelt. Letztere orientieren sich an den Wissenselementen der entwickelten Kompetenztafel. Zur Bewältigung der *Selbstlernphase* erhält die Gruppe darüber hinaus relevanten Quellcode aus dem TAS (insbesondere der Abschnitte Datenverständnis, Datenvorbereitung und Modellierung) in Form von Jupyter Notebooks. Dabei hat die Kontrollgruppe die gleiche Aufgabenstellung zu bearbeiten.

Im Zusammenhang des anschließenden *Workshops* erfolgen, wie von Erpenbeck et al. (2016) vorgeschlagen, eine Reflexion der vorherigen Phasen, sowie eine Beantwortung offen gebliebener Fragen. Außerdem werden die erzielten Ergebnisse zusammenfassend präsentiert.

Das ursprüngliche Vorgehen wird um eine finale *Lernerfolgsmessung* ergänzt. In dieser wird mit denselben Instrumenten wie in der Vorphase eine strukturierte Überprüfung des Kompetenzstands erhoben. Durch einen Pre-Post-Vergleich kann in der Folge der Lernzuwachs durch die Schulungsformate ermittelt werden.

6.2.2.3 Auswahl der Messinstrumente

Im nächsten Schritt erfolgt die Auswahl der Messinstrumente. Verschiedene Ansätze dazu erläutert Döring (2022) in ihrem Buch. Die Autorin unterscheidet dabei unter anderem Beobachtungen, Interviews und Fragebögen.

Für die Durchführung der Evaluation sind mehrere Ansätze notwendig. Im Rahmen der *Anwendungsevaluation* wird die Einhaltung der gestellten Anforderungen ermittelt. Dazu werden für diese Arbeit je nach Anforderung Experten- und Probandenbefragungen als geeignet angesehen. Gemäß den Erläuterungen von Döring (2022) ist hierzu eine vollstrukturierte schriftliche Befragung geeignet. In dieser werden geschlossene Fragen gestellt beziehungsweise geschlossene Aussagen mit Antwortvorgaben gegeben, aus denen die Befragten die jeweils passende Antwortalternative auszuwählen haben. Als Alternativen stehen Antworten auf einer vierstufigen Likert-Skala zur Verfügung.

Zur Durchführung der *Erfolgsevaluation* bedarf es an Instrumenten, welche die Überprüfung der Handlungselemente und der Wissensselemente erlauben. Für die Wissensselemente schlägt Döring (2022) sogenannte Leistungstests vor (siehe Anhang A11). Dies sind strukturierte Tests, bei denen es objektiv richtige und falsche Lösungen gibt. Leistungsindikatoren sind die Anzahl richtiger Lösungen sowie die Qualität der Lösungen. Üblicherweise wird dabei auf offene, halb-offene und geschlossene Items gesetzt. Zur Überprüfung der Handlungselemente hingegen eignen sich in Anlehnung an die Autorin semi-strukturierte Interviews mit vollstrukturierten Beobachtungen. Hierbei kommt es zu einer zielgerichteten, systematischen und regelgeleiteten Erfassung, Dokumentation und Interpretation von Verhaltensweisen unter Verwendung menschlicher Sinnesorgane (Döring 2022). Als Verhaltensweisen werden die zuvor definierten Verhaltensanker aufgegriffen, welche eine geschlossene Struktur vorgeben. Dabei werden numerische Beobachtungsdaten über das Verhalten von Personen erhoben, welche einzelne Aspekte des zu beobachtenden Geschehens hinsichtlich Intensität messen. (Döring 2022) Hierzu wird mit den Teilnehmern in einer Einzelbeobachtung ein fiktives ML-Projekt durchlaufen. Die Fragen orientieren sich an den Handlungselementen der Kompetenztafel, deren jeweilige Ausprägung anhand der Verhaltensanker bewertet wird. Um die Wahrscheinlichkeit zu verringern, dass Antworten nicht der Überführung aus der Tiefen- in die Oberflächenstruktur erliegen, wird in den Beobachtungen auf die Methode des lauten Denkens (Sarodnick und Brau 2011) gesetzt.

Im Zusammenhang mit Beobachtungen ist die Einhaltung von Reliabilität von hoher Bedeutung. Dazu wird üblicherweise eine Beobachterübereinstimmung berechnet. Hierbei betrachten mindestens zwei Beobachter die Messobjekte und protokollieren ihre Einschätzungen. Aus der Übereinstimmung lässt sich im Anschluss ein Reliabilitätskoeffizient berechnen. (Döring 2022) Zu diesem Zweck werden im vorliegenden Versuch die Interviews aufgezeichnet und die Ausprägung der Handlungselemente im Anschluss von zwei Beobachtern auf Grundlage der Verhaltensanker bewertet. Für ordinalskalierte Variablen, wie sie hier vorliegen, eignet sich dazu Cohens gewichtetes Kappa (Cohen 1968). Für dieses gilt:

$$\kappa_w = 1 - \frac{\sum w_{ij} * f_{oij}}{\sum w_{ij} * f_{eij}}$$

wobei w_{ij} einen Gewichtungsfaktor zwischen Beobachter i und Beobachter j darstellt, f_{oij} die beobachteten Häufigkeiten von i und j sowie f_{eij} die erwarteten Häufigkeiten von i und j . Mittels des Gewichtungsfaktors kann dabei der Grad der Übereinstimmung zwischen den Beobachtern näher beschrieben werden. Die Literatur kennt in diesem Zusammenhang die lineare (Mielke und Berry 2009) und die quadratische Gewichtung (Fleiss und Cohen 1973), wobei die quadratische die geläufigere Form darstellt (Graham und Jackson 1993; Schuster 2004). Finales Ziel ist, einen Reliabilitätskoeffizienten von mindestens 0,60 zu erhalten, was als gutes Ergebnis angesehen werden kann (Altman 1999).

6.2.3 Durchführung der Anwendung

Zur Durchführung der Schulung werden wie beschrieben zwei Anwendungsszenarien unternommen, welche im folgenden Abschnitt elaboriert werden. Dazu werden die Schritte der Durchführung aus Abbildung 44 jeweils für die beiden Anwendungsfälle durchlaufen.

6.2.3.1 Anwendung in der Lernfabrik

Um die Kompetenzentwicklung der Lerner mit Verwendung des TAS gegenüber einer Gruppe ohne TAS zu messen, erfolgt zum einen eine Schulung in einer kontrollierten Laborumgebung. Hierzu wird die Prozesslernfabrik CiP gewählt. Diese enthält Prozesse und Technologien realer Produktionsumgebungen und erlaubt experimentelles und problemorientiertes Lernen (Abele et al. 2015b). Als Probanden wird Rückgriff auf $n = 30$ Studenten genommen. Obwohl Lernfabriken der Definition folgend dem arbeitsorientierten Lernen zugeordnet werden müssen, ist eine Differenzierung für Studenten zu treffen. Diese bedienen im Rahmen ihrer Arbeitstätigkeiten die Fertigungsanlagen, sorgen für visuelles Management, nehmen Instandhaltungsmaßnahmen vor und treiben kontinuierliche Verbesserung in der Produktionsumgebung voran. Im Kontrast zu externen Schulungsteilnehmern stellt die CiP für die Studenten also das eigentliche Arbeitsumfeld dar, weshalb sie dort arbeitsintegriert lernen. Von den 30 an der Laborstudie teilnehmenden Studenten avisieren zum Zeitpunkt der Durchführung 13 ihren Bachelor- und 17 den Masterabschluss. Ihr Durchschnittsalter beträgt 23,97 Jahre. Abbildung 46 visualisiert die Verteilung der involvierten Studenten nach ihrem jeweiligen Studiengang.




Abbildung 46: Verteilung der Studenten nach Studiengang

Um zu verhindern, dass Studenten an der Studie teilnehmen, welche bereits umfangreiche Kenntnisse im Themenkomplex ML oder in der präventiven Instandhaltung haben, erfolgt vor Beginn der Einteilung eine Selbsteinschätzung auf Basis des Klassifikationschemas von Dreyfus und Dreyfus (1980). Darin lassen sich Lerner gemäß ihrer Vorkenntnisse in fünf Stufen (Neuling, fortgeschrittener Anfänger, Kompetenter, Gewandter, Experte) unterteilen. Solche Studenten, welche sich selbst als Kompetenter, Gewandter oder Experte einstufen, werden von der weiteren Mitarbeit ausgeschlossen. In Bezug auf ihre ML-Vorkenntnisse schätzten sich 18 Probanden als Neulinge ein und 12 als

fortgeschrittene Anfänger. Hinsichtlich der Vorkenntnisse bezüglich präventiver Instandhaltung sahen sich 26 Probanden als Neulinge und vier als fortgeschrittene Anfänger.

Als Anwendungsfall wird die Zustandsüberwachung des Sägeprozesses gewählt. Diese stellt den ersten Prozess im Wertstrom der CiP dar und ist damit essenziell für die Liefertreue der Fertigung (siehe Abbildung 47). Kommt es an der Bandsäge zu einer Störung, können die folgenden Prozesse nicht mehr mit Material bedient werden, was einen Stillstand der CiP bewirkt.




Abbildung 47: Vereinfachter Wertstrom der CiP

Befähiger in der Praxis umsetzen

Zur Anwendung des TAS sind zunächst Voraussetzungen zu schaffen, welche in Abschnitt 2.2.2 ausführlich erklärt wurden und im Kontext des Subsystems *Befähiger* außerdem Gegenstand des Gestaltungsmodells sind (siehe Abschnitt 4.4.5). Im Folgenden wird daher dargelegt, wie die *Befähiger* in der Laborumgebung umgesetzt werden.

Um die Lerner bei der Umsetzung des Projekts zu unterstützen, können angestellte Techniker und Mitarbeiter der Informationstechnik kontaktiert werden. Diese sind aufgerufen, Informationen zu Charakteristika der gewählten Anlage und zur Netzwerkinfrastruktur zu liefern. Zur Projektbearbeitung und für Recherchetätigkeiten können die Studenten darüber hinaus ihre vertraglich festgelegte Arbeitszeit verwenden. Gemeinsame Termine werden nach zeitlicher Verfügbarkeit und Arbeitslast gewählt. Insofern Bedarf besteht, können die Studenten neben den oben genannten Mitarbeitern weitere Angestellte befragen. Die jeweiligen Vorgesetzten können aufgrund anderweitiger Verpflichtungen jedoch nicht eingebunden werden. Das Gelernte lässt sich perspektivisch auf andere in der CiP vorhandene Werkzeugmaschinen übertragen. Lerntempo und Lernumgebung sind den Studenten überlassen. Dies kann in gemeinsamen Terminen oder in Einzelarbeit erfolgen.

Erprobung von Handlungsaufgabe und Messinstrumenten

Vor der eigentlichen Schulungsdurchführung sind gemäß dem Vorgehen aus Abbildung 44 die Handlungsaufgabe und die Messinstrumente zu testen. Hierzu wurde auf Grundlage von Abbildung 45 eine Testschulung aufgebaut. In dieser konnte festgestellt werden, dass die ursprünglich definierten Verhaltensanker nicht vollständig trennscharf formuliert sind. Insbesondere fiel in den Interviews auf, dass einzelne Teilnehmer Schwierigkeiten mit den Ausführungen der Fragen hatten. Daher erfolgte im Nachgang eine Konkretisierung der Wortlaute von Verhaltensankern und Fragen. Zudem musste die Rolle der Beobachter spezifiziert werden. In der Testschulung ließen sich Eingriffe dieser in die Handlungsaufgabe feststellen, welche die Teilnehmer in ihrer Selbstbestimmtheit und dem

eigenständigen Ausprobieren eingrenzte. Entsprechend wurden die Beobachter bezüglich ihrer Rolle und ihres zu erwartenden Verhaltens nachgeschult.

Schulungen durchführen

Die Umsetzung in der Lernfabrik fand im Zeitraum von Mai 2024 bis Januar 2025 statt. Involvierte Studenten wurden in diesem Zusammenhang paritätisch auf Experimental- und Kontrollgruppe ($n_{EG} = n_{KG} = 15$) verteilt, wobei sie stets in Kleingruppen von drei Studenten die Problemstellung bearbeiten sollten. Auf Grundlage von Gesprächen mit Angestellten der CiP identifizierten die Studenten, dass durch Vorarbeiten bereits verschiedene Sensoren an der Anlage verbaut sind, welche mittels OPC-UA Daten an eine Speicherprogrammierbare Steuerung (SPS) transportieren. Zur Vergleichbarkeit der Ergebnisse wurde jedoch im Vorfeld ein Datensatz aufgenommen und dieser anschließend synthetisch erweitert, sodass Trends im Zeitspektrum erkennbar sind. Die Aufnahme mussten die Studenten folglich nicht selbst vornehmen. Hingegen waren sie anschließend aufgefordert, durch eigene Vorkenntnisse und Gespräche mit Domänenexperten ein Datenverständnis aufzubauen. Dieses nutzten sie anschließend, um die Daten geeignet vorzubereiten und verschiedene Modelle zu trainieren. Es zeigte sich in der projektbegleitenden nicht-standardisierten Beobachtung, dass stets mehrere Iterationen von Datenvorbereitung und Modellierung notwendig waren.

6.2.3.2 Anwendung in der industriellen Praxis

Weiterhin fand das TAS im Zeitraum November 2024 bis Januar 2025 bei einem Hersteller für Oberflächenmaterialien Anwendung. An der gewählten Druckanlage werden verschiedene Farben auf ein Papier gedruckt. Zu diesem Zweck läuft das Papier über Druckzylinder, welche über Rakel mit der Maschine verbunden sind. Im Zeitverlauf zeigen die Rakel Verschleißerscheinungen, welche über eine Schwingungsmessung detektierbar sind. Der gegenwärtige Zustand erlaubt keine Rückschlüsse über den Zustand der angebrachten Werkzeuge, was in der Konsequenz zu Ausschuss führt. Des Weiteren wird durch den eintretenden Verschleiß der Druckzylinder über die Lauflänge die Farbwiedergabe negativ beeinflusst. Ziel des Unternehmens war daher eine Zustandsüberwachung, durch welche eine Verschleißerkennung von Rakel und Zylinder möglich ist und welche in der Konsequenz den Ausschuss reduziert.

Befähiger in der Praxis umsetzen

Zur Realisierung des Vorhabens werden jene $n = 2$ Mitarbeiter, in deren Verantwortungs- und Arbeitsbereich die Druckmaschine fällt, von ihren sonstigen Aufgaben zeitweise freigestellt. Sie können damit *Vorphase*, *Kickoff* sowie *Workshop* und *Lernerfolgsmessung* in Vollzeit absolvieren. Die *Selbstlernphase* hingegen erfolgt über einen Zeitraum von rund 1,5 Monaten parallel zu anderen Aufgaben. Außerdem können jederzeit Mitarbeiter der Informationstechnik kontaktiert werden. Bedingt durch die bestehenden Vorarbeiten sind keine finanziellen Ressourcen notwendig. Aufgebaute Überstunden in den einzelnen Phasen können zu einem späteren Zeitpunkt wieder abgebaut werden. Die Mitarbeiter erhalten außerdem soziale Unterstützung bei aufkommenden Fragen

durch andere Abteilungen (beispielsweise Technologieentwicklung und Informationstechnik). In dedizierten Sitzungen sind darüber hinaus die Werks- und Produktionsleitung eingebunden, womit deren Interesse am Lernfeld sichergestellt ist. Die Ergebnisse des Vorhabens lassen sich perspektivisch auf andere Druckwerke am gegebenen Prozess sowie weitere vergleichbare Druckmaschinen am Standort übertragen. Selbstbestimmtes Lernen orientiert sich im Anwendungsszenario an Unternehmenszielen, da Lernziel und -thema unternehmensseitig vorgegeben sind. Hingegen haben die Teilnehmer hinsichtlich Lerntempo und -umgebung Entscheidungsspielraum.

Erprobung von Handlungsaufgabe und Messinstrumenten

Für die Anwendung in der industriellen Oberflächenbearbeitung wurde keine Erprobung vorgenommen. Da die Umsetzung in der Lernfabrik aber zeitlich vor dem Feldversuch terminiert war und durch sie bereits eine Nachschärfung von Messinstrumenten und Rolle der Beobachter vorgenommen wurde, kann sie als Erprobung von Handlungsaufgabe und Messinstrumenten angesehen werden.

Schulungen durchführen

Zur Erhöhung der Prozessverfügbarkeit wurden die beiden Mitarbeiter mit der Projektierung einer ML-basierten Lösung beauftragt, welche anhand des entwickelten TAS erfolgte. Beide Mitarbeiter sahen sich sowohl in Bezug auf ihre ML-Vorkenntnisse als auch bezüglich der präventiven Instandhaltung als Neulinge an. Für die Durchführung des Projekts erhielten sie Unterstützung seitens der Informationstechnik, elektrischen Instandhaltung und Produktion. Aufgrund von personellen und zeitlichen Beschränkungen des Unternehmens konnte keine Vergleichsgruppe gebildet werden. Im Verlauf des Projekts wurden die Nacharbeitsrate und der Ausschuss als relevante Unternehmenskennzahlen identifiziert, welche einen späteren Projekterfolg messbar machen. Zudem wurde festgehalten, dass der Schwingungssensor aufgenommene Daten mittels des Busprotokolls Profinet an eine interne Datenbank überträgt. Der Schwerpunkt des Projekts lag auf der Datenaufnahme und dem Datenverständnis. Dabei stellte die Selektion der richtigen statistischen Merkmale eine Herausforderung dar, welche ein hohes Maß an Zeit benötigte. Auf Grundlage der Modellierungsergebnisse wurde final entschieden, dass zu einem späteren Zeitpunkt weiterführende Maßnahmen notwendig sind. Diese konnten nicht mehr im Rahmen der Dissertation begleitet werden. Erarbeitete Zwischenstände aus den Prozessmodellabschnitten *Datenverständnis* und *Datenvorbereitung* zeigt Abbildung 48.




Abbildung 48: Zwischenstände aus der Anwendung in der betrieblichen Praxis, links: Datenverständnis, rechts: Datenvorbereitung (Werkzeugverschleiß in schwarz)

6.3 Auswertung von Anwendungs- und Erfolgsevaluation

In diesem Abschnitt erfolgt eine Auswertung der zuvor getätigten Schritte. Hierbei wird zunächst die Anwendungsevaluation (Abschnitt 6.3.1) vorgenommen. Im Anschluss daran erfolgt die Erfolgsevaluation (Abschnitt 6.3.2) beziehungsweise Validierung.

6.3.1 Evaluation der inhaltlichen und formalen Anforderungen

Zur Überprüfung auf Einhaltung der inhaltlichen und formalen Anforderungen wurden zwei vollstrukturierte digitale Fragebögen verwendet. Diese wurden einerseits an die im Zuge der Anwendung beteiligten $n = 17$ Probanden der Experimentalgruppen in Labor und Feld ausgehändigt. Sie sollten jene inhaltlichen Anforderungen an das TAS bewerten, welche unmittelbaren Einfluss auf ihre Arbeiten haben. Dies umfasst IA 4, IA 5, IA 6 und IA 9 (Bezeichnungen siehe Tabelle 16). Antwortmöglichkeiten bestanden dabei auf einer vierstufigen Likert-Skala. Durch die gerade Anzahl an Antworten mussten sich die Befragten für eine positive oder negative Bewertung entscheiden. Der oftmals auftretende Hang zur Mitte wurde dadurch vermieden. Mit Hinblick auf IA 9 sollten sie jeweils bewerten, in welchem Umfang die im Vorfeld als relevant eingestuft 22 Basis-, Leistungs- und Begeisterungsmerkmale im TAS umfasst sind. Der unten präsentierte Wert stellt dabei den Mittelwert aller bewerteten Merkmale dar.

Die verbleibenden inhaltlichen Anforderungen sowie die formalen Anforderungen wurden andererseits $n = 17$ Experten aus der Praxis vorgelegt. Diese befassen sich berufsseitig mit der Weiterbildung von Industrievertretern oder der Entwicklung digitaler Assistenzsysteme und können aufgrund ihrer Profession einschätzen, inwiefern die gestellten Anforderungen erfüllt sind. Auch hier galt es, Antworten auf einer vierstufigen Likert-Skala zu geben. Nicht mit betrachtet wurde Anforderung IA 1, da deren Erfüllung im Zuge der *Erfolgsevaluation* (siehe Abschnitt 6.3.2) eingeordnet wird.

Die Antworten wurden daraufhin von 1 bis 4 codiert und auf deren Grundlage das jeweilige arithmetische Mittel bestimmt. Eine Anforderung kann dann als erfüllt angesehen werden, wenn die arithmetisch-mittlere Bewertung im Bereich von „Stimme eher zu“ und „Stimme zu“ liegt, beziehungsweise wenn gilt: $3,00 \leq \bar{x}_i \leq 4,00$ für Anforderung i . Die Mittelwerte der einzelnen inhaltlichen und formalen Anforderungen finden sich zusammenfassend in Tabelle 16.²²

Tabelle 16: Bewertung inhaltlicher und formaler Anforderungen

	Nr.	Anforderungsbezeichnung	Mittlere Bewertung	Bewertergruppe
Inhaltliche Anforderungen an das TAS	IA 2	Non-formales Lernen durch Exposition	3,24	Experten
	IA 3	Lernförderliche Gestaltung	3,41	Experten
	IA 4	Systematisches Vorgehen	3,53	Probanden
	IA 5	Planung einer Netzwerkinfrastruktur	2,76	Probanden
	IA 6	Unterstützung bei Datenaufnahme	3,24	Probanden
	IA 7	Spezifisches ML-Modell	3,53	Experten
	IA 8	Datenmanagement zum Speichern und Verarbeiten	3,18	Experten
	IA 9	Menschzentrierte grafische Benutzeroberfläche	3,15	Probanden
	IA 10	Technologie	3,24	Experten
Formale Anforderungen an das Gestaltungsmodell	FAG 1	Vollständigkeit	3,47	
	FAG 2	Relevanz	3,29	
	FAG 3	Übersichtlichkeit	3,24	Experten
	FAG 4	Adaptivität	3,12	
	FAG 5	Implementierbarkeit	2,82	
Formale Anforderungen an die Methode	FAM 1	Objektivität	3,29	
	FAM 2	Reliabilität	3,18	
	FAM 3	Validität	3,47	
	FAM 4	Generalisierbarkeit	3,06	Experten
	FAM 5	Einfachheit	3,24	
	FAM 6	Anpassungsfähigkeit	3,24	
	FAM 7	Handhabbarkeit	3,53	

Auf Grundlage von Tabelle 16 kann resümiert werden, dass acht der neun untersuchten inhaltlichen Anforderungen durch das entwickelte TAS erfüllt werden, da der geforderte Schwellwert erreicht wird. Lediglich die Planung der Netzwerkinfrastruktur wird mit einem Mittelwert von $\bar{x}_{IA5} = 2,76$ nicht ausreichend gut bewertet. Dies kann

²² Für eine Detailanalyse der Ergebnisse siehe Rosemeyer (2025b).

möglicherweise mit der hohen fachlichen Komplexität beim Aufbau einer Netzwerkinfrastruktur zusammenhängen. So äußerten zahlreiche Probanden, dass sie mangels Vorkenntnisse diesen Schritt nur sehr schwer durchführen konnten. Nichtsdestotrotz wandte sich lediglich eine Experimentalgruppe dafür umfangreich an einen dedizierten Mitarbeiter der CiP, um sich Unterstützung einzuholen. Die verbleibenden vier Gruppen versuchten diese Aufgabe durch Internetrecherche oder Vorkenntnisse selbst zu lösen. Mit Hinblick auf zukünftige Arbeiten könnten weiterführende Erläuterungen Abhilfe schaffen. Denkbar ist auch, dass in der industriellen Praxis aufgrund von Berechtigungen und Verantwortungsbereichen stärker als in der Laborumgebung auf die entsprechenden Fachabteilungen zurückgegriffen wird.

Ein vergleichbares Bild zeigt sich bei den formalen Anforderungen an das Gestaltungsmodell. Auch hier können mit Ausnahme von Anforderung FAG 5 ($\bar{x}_{FAG5} = 2,82$) alle Anforderungen als erfüllt angesehen werden. In der Diskussion mit den Experten nach dem Ausfüllen zeigten sich viele Befragte kritisch hinsichtlich der Implementierbarkeit des Modells. Immerhin, so die Aussage der Experten, ist die Entwicklung einer Software nicht binnen kurzer Zeit realisierbar, sondern bedarf Iterationen. Mit Fokus auf das vorgelegte Gestaltungsmodell befanden die Experten darüber hinaus FAG 5 als schwierig zu bewerten, da sie die Operationalisierung nicht selbst durchgeführt haben.

Letztlich lässt sich auf Basis der Ergebnisse aus Tabelle 16 festhalten, dass alle formalen Anforderungen an die Operationalisierungsmethode den definierten Schwellwert überschreiten und folglich als erfüllt angesehen werden können.

6.3.2 Evaluation der Lernziele

Ob und inwiefern die inhaltliche Anforderung IA 1 (Erreichung von Lernzielen) erfüllt ist, wird anhand einer Analyse der Ergebnisse aus Pre- und Posttest festgehalten. Im Folgenden werden daher die Ergebnisse aus der Anwendung in der Lernfabrik und der industriellen Praxis beschrieben. Eine Interpretation der Ergebnisse wird im anschließenden Abschnitt vorgenommen.²³

6.3.2.1 Anwendung in der Lernfabrik

Gemäß Abbildung 45 wurden die beteiligten Studenten sowohl im Vorfeld als auch im Nachgang bezüglich ihrer Wissenskenntnisse und Handlungsfähigkeiten in der Anwendung von ML-Lösungen befragt. Das Ausmaß an Wissen wurde dabei mittels eines Leistungstests und der Umfang der Handlungsfähigkeit durch ein semi-strukturiertes Interview und einer Einstufung in Verhaltensanker bewertet. Für beide Instrumente können daraufhin Pre-Post-Vergleiche vorgenommen werden.

In Abbildung 49 ist die Veränderung der Handlungselemente der Probanden in Form eines Boxplots aufgetragen. Hier ist zunächst ersichtlich, dass das Handlungsniveau sowohl

²³ Für eine Detailanalyse der Ergebnisse siehe Rosemeyer (2025a).

bei der Experimental- als auch bei der Kontrollgruppe gestiegen ist. Die Durchführung der Schulung hat folglich einen Mehrwert für beide Gruppen generiert. Während der Median der Experimentalgruppe von $\tilde{v}_{EG,vorher} = 0,94$ auf $\tilde{v}_{EG,nachher} = 1,94$ steigt, verändert sich der Median der Kontrollgruppe weniger stark ($\tilde{v}_{KG,vorher} = 1,00$ zu $\tilde{v}_{KG,nachher} = 1,81$). Es ist allerdings auch zu erkennen, dass ein hoher Interquartilsabstand der Experimentalgruppe im Posttest verbleibt ($IQA_{v,EG,nachher} = 0,53$, $IQA_{v,KG,nachher} = 0,34$). Die Probanden weisen folglich ebenso nach der Durchführung der Schulung ein unterschiedliches Handlungsniveau auf.




Abbildung 49: Veränderung der Handlungselemente (links: EG, rechts: KG)

Bei einer Betrachtung der Veränderung der Teilkompetenzen (siehe Tabelle 17) ist weiterführend eine Verbesserung aller einzelnen Handlungselemente ersichtlich - sowohl in der Kontrollgruppe als auch der Experimentalgruppe. Hierbei übersteigt die Änderung des arithmetisch-mittleren Verhaltensankers $\Delta\bar{v}_G, G \in \{EG, KG\}$ der Experimentalgruppe die der Kontrollgruppe leicht ($\Delta\bar{v}_{EG} = 0,84$ bzw. $\Delta\bar{v}_{KG} = 0,77$), was in der Folge zu einer Angleichung des mittleren Handlungsniveaus führt ($\Delta\bar{v}_{EG,vorher} = 0,92$ bzw. $\Delta\bar{v}_{KG,vorher} = 1,03$ zu $\Delta\bar{v}_{EG,nachher} = 1,76$ bzw. $\Delta\bar{v}_{KG,nachher} = 1,80$). In der Detailauswertung der Teilkompetenzen lassen sich drei Fälle hinsichtlich der Veränderung unterscheiden. Diese werden in der Folge sukzessive beschrieben (mit Teilkompetenz $i \in \{2,3,4,6,8,9,11,12\}$).

- Fall $\Delta\bar{v}_{i,EG} > \Delta\bar{v}_{i,KG}$: Der erste Fall umfasst jene Teilkompetenzen, bei denen die Änderung der mittleren Bewertung der Experimentalgruppe größer ist als die der Kontrollgruppe. So ist die Fähigkeit der Experimentalgruppe, den richtigen Algorithmus aus einer vorgegebenen Auswahl auszuwählen (TK 8), bereichsübergreifenden Austausch mit Hinblick auf ML-Anwendungen zielorientiert zu gestalten (TK 9) sowie notwendige Schritte bei der Einführung strukturiert anzuwenden (TK 11), in stärkerem Ausmaß als bei der Kontrollgruppe gestiegen.
- Fall $\Delta\bar{v}_{i,EG} < \Delta\bar{v}_{i,KG}$: Der zweite Fall hingegen inkludiert jene Teilkompetenzen, bei denen der mittlere Verhaltensanker der Kontrollgruppe stärker gestiegen ist als bei der Experimentalgruppe. So sind sie in stärkerem Ausmaß in der Lage, einen Datensatz für ML-Modelle in hoher Quantität und Qualität anzufertigen

(TK 4) sowie Anwendungsfälle in der Produktion zu illustrieren (TK 6). Dabei ist der Zuwachs ersterer Teilkompetenz nur moderat, während für zweite eine höhere Abweichung zu identifizieren ist.

- Fall $\Delta\bar{v}_{i,EG} \cong \Delta\bar{v}_{i,KG}$: Der dritte und letzte Fall umfasst jene Teilkompetenzen, welche ungefähr in gleichem Maße angestiegen sind. Darunter fallen jene Teilkompetenzen, für die gilt: $|\Delta\bar{v}_{i,EG} - \Delta\bar{v}_{i,KG}| \leq 0,03$. In diesem Zusammenhang kann zunächst festgehalten werden, dass die Fähigkeit beider Gruppen, in der eigenen Produktion aufgezeichnete Daten mit Hinblick auf deskriptive Statistik erklären zu können (TK 2), ebenso wie jene, notwendige Voraussetzungen für die eigene Produktion zu identifizieren (TK 12), in gleichem Umfang gestiegen ist. Hingegen kann ein geringfügiger Unterschied hinsichtlich der Fähigkeit, Ergebnisse von ML-Modellen zu verstehen und faktenbasiert einzuschätzen (TK 3), festgehalten werden.

Tabelle 17: Vergleich der Handlungselemente von Experimental- und Kontrollgruppe

Teilkompetenz	Arithmetisch-mittlere Veränderung Experimentalgruppe	Arithmetisch-mittlere Veränderung Kontrollgruppe
TK 2	0,83	0,83
TK 3	0,90	0,87
TK 4	0,50	0,57
TK 6	0,60	0,70
TK 8	1,00	0,87
TK 9	1,00	0,73
TK 11	1,07	0,77
TK 12	0,80	0,80
Mittelwert	0,84	0,77

Zur Bewertung der Wissensselemente wird auf die aggregierten Punkte im Wissenstest je Teilkompetenz Rückgriff genommen. Hierbei ist von Relevanz, dass die maximal zu vergebenden Punkte innerhalb des Leistungstest nicht gleichverteilt sind. Die maximale Punktzahl je Teilkompetenz ist daher aufgabenspezifisch. Ähnlich den Handlungselementen lässt sich auch hier beobachten, dass der Wissensumfang in allen Teilkompetenzen einerseits und in der Summe bei allen Probanden andererseits gestiegen ist (siehe Abbildung 50 und Tabelle 18). Hinsichtlich des Wissenszuwachs ist zudem festzuhalten, dass der Median der aggregierten Punkte je Proband in der Experimentalgruppe von $\tilde{p}_{EG,vorher} = 2,00$ auf $\tilde{p}_{EG,nachher} = 10,50$ stärker steigt als bei der Kontrollgruppe ($\tilde{p}_{KG,vorher} = 3,00$ zu $\tilde{p}_{KG,nachher} = 7,00$). Erkennbar ist letztlich, dass das Wissensniveau in der Experimentalgruppe nach Durchführung der Schulung schwankt. So liegt der Interquartilsabstand $IQA_{p,EG,nachher} = 8,75$ deutlich größer als in den anderen Versuchsszenarien ($IQA_{p,EG,vorher} = 5,25$, $IQA_{p,KG,vorher} = 6,50$, $IQA_{p,KG,nachher} = 7,25$).




Abbildung 50: Veränderung der Wissenselemente (links: EG, rechts: KG)

Hinsichtlich der einzelnen Teilkompetenzen lässt sich darüber hinaus beobachten, dass der Anstieg der erzielten Punkte in drei von vier Fällen bei der Experimentalgruppe höher ist als bei der Kontrollgruppe (siehe Tabelle 18). Es lassen sich daher zwei Fälle hinsichtlich $\Delta\bar{p}_{i,G}$; $G \in \{EG, KG\}$, $i \in \{1,5,7,10\}$ unterscheiden. Für diese gilt:

- Fall $\Delta\bar{p}_{i,EG} > \Delta\bar{p}_{i,KG}$: In diesem Zusammenhang lässt sich beobachten, dass die Fähigkeiten der Experimentalgruppe, grundlegende Begriffe im Kontext von ML-Anwendungen beschreiben zu können (TK 1), die Funktionsweise von ML-Algorithmen darstellen zu können (TK 7) sowie notwendige Schritte bei der Einführung von ML-Anwendungen zu erläutern (TK 10), im Vergleich zur Kontrollgruppe in höherem Maße angestiegen sind.
- Fall $\Delta\bar{p}_{i,EG} < \Delta\bar{p}_{i,KG}$: Dieser Fall inkludiert lediglich die Fähigkeit, verschiedene potenzielle Anwendungsfälle für ML in der Produktion aufzuzählen (TK 5).

Tabelle 18: Vergleich der Wissenselemente von Experimental- und Kontrollgruppe

Teilkompetenz	Arithmetisch-mittlere Veränderung Experimentalgruppe	Arithmetisch-mittlere Veränderung Kontrollgruppe
TK 1	1,47	0,83
TK 5	0,47	0,90
TK 7	2,23	1,73
TK 10	1,90	0,70
Summe	6,03	4,16

6.3.2.2 Anwendung in der industriellen Praxis

Die Anwendung in der industriellen Praxis wurde nach selbigem Vorgehen wie im Labor strukturiert. Auch hier kamen die genannten Instrumente für den Pre- und Posttest zur Anwendung. Da mit $n = 2$ Probanden die Stichprobe sehr klein war und aufgrund personeller Ressourcen keine Kontrollgruppe eingesetzt werden konnte, wird an dieser Stelle auf eine umfangreiche statistische Analyse verzichtet. Vielmehr werden zu verzeichnende

Veränderungen präsentiert. Weitere Ergebnisse sind darüber hinaus in Tabelle 19 zusammengefasst.

Es ist ersichtlich, dass sich bei den Wissenselementen nur geringfügige Änderungen ergaben. Die vorgestellten und in das TAS integrierten Theorieinhalte scheinen folglich nicht in die Tiefenstruktur der Mitarbeiter überführt worden zu sein. So konnten die Probanden im Post-Leistungstest lediglich leicht besser potenzielle Anwendungsfälle für ML in der Produktion nennen (TK 5) und notwendige Projektschritte aufzeichnen (TK 10). Insbesondere konnten die theoretischen Grundlagen von ML-Anwendungen nicht wiedergegeben werden (TK 1 und TK 7).

Ein anderes Bild zeigt sich bei den Handlungselementen. Im Kontrast zum Pretest waren die Mitarbeiter im Posttest in höherem Maße in der Lage, einen geeigneten Datensatz anzufertigen (TK 4) und im Anschluss aufgezeichnete Daten mit Hinblick auf deskriptive Statistik erklären zu können (TK 2). Auch die Fähigkeit zum zielorientierten Austausch mit weiteren relevanten Abteilungen (TK 9) konnte gestärkt werden, sowie die strukturierte Bearbeitung eines ML-Projekts (TK 11). Letztlich stieg die Fähigkeit, die Ergebnisse eines ML-Algorithmus faktenbasiert zu erläutern (TK 3) und auf Grundlage von Leistungsmetriken einen optimalen Algorithmus auszuwählen (TK 8). Keine Verbesserung konnte hinsichtlich der notwendigen Voraussetzungen identifiziert werden (TK 12).

In der Summe zeigt sich, dass mittels des TAS die Handlungsfähigkeit bei der Implementierung einer ersten ML-Lösung in der industriellen Anwendung gestärkt werden konnte. Hinsichtlich der Wissenselemente ließen sich jedoch keine wesentlichen Verbesserungen erzielen. Erklärungsansätze für diese Ergebnisse werden im folgenden Abschnitt 6.4 geliefert.

Tabelle 19: Veränderung der Teilkompetenzen in der industriellen Anwendung

Teilkompetenz	Arithmetisch-mittlere Veränderung Handlungselemente	Arithmetisch-mittlere Veränderung Wissenselemente
TK 1		0
TK 2	1,5	
TK 3	0,5	
TK 4	1,5	
TK 5		0,5
TK 6	0,5	
TK 7		0
TK 8	0,5	
TK 9	1,5	
TK 10		0,75
TK 11	1,5	
TK 12	0	

Auf Grundlage der in diesem Abschnitt angeführten Ergebnisse kann in der Summe festgehalten werden, dass das entwickelte TAS die inhaltliche Anforderung IA 1 erfüllt.

6.3.2.3 Beobachterübereinstimmung

Mit Hinblick auf die Reliabilität der verwendeten Instrumente erfolgt final eine Ermittlung der Beobachterübereinstimmung. Als Kennzahl wird gemäß Abschnitt 6.2.2.3 Cohens gewichtetes Kappa bestimmt, wobei in Anlehnung an die zitierte Literatur quadrierte Gewichte genutzt werden. Für die Übereinstimmungsbewertung erfolgt eine Gesamtauswertung über den vollständigen Bewertungsbogen und eine Detailanalyse jeder einzelnen Teilkompetenz (siehe Tabelle 20). Bei näherer Betrachtung fällt auf, dass sowohl die Items insgesamt ($\kappa_{w,ges} = 0,68$) als auch jedes einzelne Item ein $\kappa_{w,i} > 0,60, i \in \{2,3,4,6,8,9,11,12\}$ aufweist und daher im Sinne von Altman (1999) als „gut“ eingestuft werden kann. Es ist jedoch auch ersichtlich, dass vier Items den geforderten Grenzwert nur sehr knapp überschreiten.

Tabelle 20: Cohens gewichtetes Kappa je Handlungselement

Teilkompetenz	κ_w	Einordnung gemäß Altman (1999)
TK 2	0,84	Sehr gut
TK 3	0,67	Gut
TK 4	0,61	Gut
TK 6	0,61	Gut
TK 8	0,70	Gut
TK 9	0,60	Gut
TK 11	0,63	Gut
TK 12	0,70	Gut
Gesamt	0,68	Gut

6.4 Kritische Diskussion der Ergebnisse

In diesem Abschnitt werden die im vorangegangenen Abschnitt vorgestellten Ergebnisse kritisch diskutiert und interpretiert. Ebenso werden getroffene Einschränkungen bei der Entwicklung des TAS erörtert. Auf Basis dessen lassen sich in Anlehnung an Abschnitt 2.4 Empfehlungen für weitere Arbeiten ableiten.

Hinsichtlich der Identifikation von ML-Anwendungsfällen

Wie in Abschnitt 6.3.2 präsentiert, stiegen die arithmetisch-mittleren Bewertungen der Fähigkeit, verschiedene potenzielle Anwendungsfälle für ML in der Produktion aufzuzählen und der Fähigkeit, Anwendungsfälle in der eigenen Produktionsumgebung zu identifizieren in der Kontrollgruppe stärker an als in der Experimentalgruppe. Dies kann darauf zurückzuführen sein, dass der Kontrollgruppe im Zuge des Kickoffs mögliche Anwendungsfälle vorgestellt wurden und sie somit notwendiges Faktenwissen erlangten. Im Kontrast sollte sich die Experimentalgruppe die Anwendungsfälle über die integrierten Theorieinhalte nach eigenem Ermessen und den jeweiligen Vorkenntnissen selbst beibringen. In der umsetzungsbegleitenden (nicht-strukturierten) Beobachtung fiel dabei

auf, dass die Experimentalgruppe die jeweiligen Theorieinhalte oftmals übersprang und vielmehr unmittelbar mit der Projektdurchführung begann. Für den Anwendungsfall der Zustandsüberwachung haben sie somit mehr Handlungswissen erlangt, welches jedoch zur Beantwortung der Fragestellungen im Posttest nicht von Relevanz war. Es lässt sich daher festhalten, dass die vorgenommene Durchführung über Selbstlernen hinsichtlich ML-Anwendungsfällen nicht geeignet ist und in zukünftigen Vorhaben besser auf klassische Weiterbildungen gesetzt werden sollte, wie sie die Kontrollgruppe erfahren hat.

Hinsichtlich der Erstellung eines ML-geeigneten Datensatzes

Ebenso lässt sich in den Ergebnissen der Erfolgsevaluation beobachten, dass die Kontrollgruppe in höherem Maße in der Lage ist, einen für ML-Anwendungen geeigneten Datensatz zu erstellen als die Experimentalgruppe. Dies ist von besonderer Bedeutung, da die an der Anwendungsevaluation beteiligte Experimentalgruppe der Auffassung ist, dass das verwendete TAS ihnen bei der Erstellung eines geeigneten Datensatzes half (siehe Tabelle 16). Auf Grundlage der beiden konträren Befunde kann eine Divergenz in der Selbsteinschätzung durch die Probanden und die Fremdeinschätzung durch Leistungstest und Handlungsbeobachtung resümiert werden. Möglich ist, dass der geringer ausfallende Handlungsanstieg durch die Experimentalgruppe auf mangelnde Erläuterungen zum genannten Vorgehen zurückzuführen ist. Da die Erstellung eines Datensatzes allerdings einzelfallabhängig ist und spezifische Begebenheiten von Anwendungsfällen berücksichtigen müssen, sind im erarbeiteten TAS nur geringfügige Beschreibungen vorhanden, welche zudem durch die Nutzer interpretiert werden mussten. Mit Hinblick auf zukünftige Arbeiten sind folglich weiterführende Erläuterungen, wie Daten aufgenommen und aufbereitet werden müssen, notwendig.

Hinsichtlich des gleichen Handlungsanstiegs in EG und KG

Die Veränderungen der Handlungselemente in Fall 3 der Laborstudie kann auf die methodische Umsetzung der Materialien von Experimental- und Kontrollgruppe zurückzuführen sein. Beide Gruppen bekamen im Zuge des Datenverständnisses und der Modellierung Diagramme sowie Leistungsmetriken präsentiert, ohne hierzu weiterführenden Aufwand betreiben zu müssen. Folglich gab es in diesem Zusammenhang keine systematischen Unterschiede, welche sich in gleichen Fähigkeitszuwächsen widerspiegeln.

Von Relevanz ist auch die Verbesserung der Fähigkeit, notwendige Voraussetzungen für die eigene Produktion zu identifizieren. Immerhin stellt die dahinterliegende Anforderung (IA 5) einen Kernbestandteil neu zu entwickelnder TAS dar und ist eine essenzielle Voraussetzung zur gewinnbringenden Anwendung in KMU. Zwar ist mit $\Delta \bar{v}_{EG,TK12} = 0,80$ eine Verbesserung zu verzeichnen, woraus ein Mehrwert der Lösung festgehalten werden kann. Jedoch unterscheidet sich dieser nicht von der Kontrollgruppe. Es kann angenommen werden, dass folglich die Erläuterungen in der Umsetzung nicht ausreichten und noch weiter konkretisiert werden sollten.

Hinsichtlich der Ausgangslage der Studenten

Wie in Abbildung 49 und Abbildung 50 erkenntlich, wiesen die Studenten der Experimentalgruppe vor der Anwendung geringeres Grundwissen und Grundhandlungsfähigkeiten auf. Dies bietet im Gegenzug mehr Potenzial für Verbesserungen als bei der Kontrollgruppe, was Einfluss auf den Pre-Post-Vergleich hat. Da die Studenten allerdings randomisiert auf die beiden Gruppen verteilt wurden, liegt hierbei keine bewusste Verzerrung vor. Vielmehr haben sich die Unterschiede zufällig ergeben.

Hinsichtlich der Überführung von der Tiefen- in die Oberflächenstruktur

Trotz der im vorherigen Abschnitt beschriebenen Verbesserungen lässt sich bei einer Detailanalyse der Ergebnisse resümieren, dass nicht in allen Einzelfällen die Bewertung im Posttest gegenüber dem Pretest gestiegen ist. Tatsächlich ist die Veränderung im Wissenstest in 7,3% der Einzelbewertungen echt kleiner als null. Demnach waren die erzielten Punkte im Pretest höher als im Posttest. Es ist daher anzunehmen, dass in den entsprechenden Szenarien die Probanden ein Transformationsproblem aufwiesen: sie schienen auf der Tiefenstruktur über das notwendige Wissen zu verfügen, konnten es im entsprechenden Transformationsprozess jedoch nicht auf die beobachtbare Oberflächenstruktur überführen (siehe hierzu auch Abschnitt 2.2.1).

Ergänzend stellt das beschriebene Transformationsproblem eine Einschränkung der erzielten Ergebnisse aller Probanden dar. Da sich lediglich Performanzen unmittelbar beobachten lassen, ist es möglich, dass einzelne Probanden über mehr Wissen oder Handlungsfähigkeit verfügen, als sie im Zuge von Pre- oder Posttest abrufen konnten. Dies kann beispielsweise auf nicht vollständig verstandene Aufgabenstellungen zurückzuführen sein – insbesondere bei solchen Probanden, mit denen nicht in der jeweiligen Erstsprache kommuniziert wurde. In der Folge ist denkbar, dass einzelne Probanden unbeabsichtigt schlechter bewertet wurden als es ihren Kompetenzen entspricht. Um dies in den Interviews bestmöglich zu verhindern, wurden im Zweifelsfall einzelne Fragen mit verändertem Wortlaut wiederholt und auf die Methode des lauten Denkens gesetzt. Bei den Leistungstest war dies aufgrund der Standardisierung nicht möglich.

Hinsichtlich der Veränderungen in der Industrie

Letztlich ließen sich nur geringfügige Handlungs- und Wissensveränderungen bei der Anwendung in der Industrie beobachten (siehe Tabelle 19). Hinsichtlich der Wissensselemente kann dies darauf zurückgeführt werden, dass die inkludierten Theorieinhalte seitens der Mitarbeiter zugunsten einer Projektbeschleunigung übersprungen wurden und zudem Fachbegriffe nicht recherchiert wurden. Vielmehr wurde die Fehlerlosigkeit der Inhalte des TAS angenommen. Zudem liegt der Arbeitshintergrund der beteiligten Mitarbeiter in der Prozessexpertise, während Datenauswertungen bisher kaum notwendig waren. Entsprechende Kompetenzen waren daher in der Vergangenheit nur geringfügig vonnöten. Zugleich reichte die in der Summe kurze Projektdauer nicht aus, hier umfangreiche Kompetenzen aufzubauen. In der Anwendung wurde aufgrund des komplexen Anwendungsfalls hingegen viel Zeit für das Datenverständnis aufgebracht. Eine entsprechende

Verbesserung der Handlungsfähigkeit ist in den entsprechenden Teilkompetenzen ersichtlich. Die konsekutiven Datenvorbereitung und Modellierung wurden im Anschluss als Ausblick auf eine mögliche Lösung genutzt. Hingegen konnten sie nicht vollumfänglich durchlaufen werden, da sich in den Daten Begebenheiten zeigten, welche zur Projektdurchführung nicht vollumfänglich kausal erklärt werden konnten. Entsprechend wurden die beiden Schritte in zeitlich kürzerem Umfang durchlaufen. Nichtsdestotrotz stellte die Anwendung des TAS nach Ansicht der Beteiligten einen sinnvollen und strukturierten Ansatz dar, um sich dem Themenfeld ML-basierte Zustandsüberwachung zu nähern. Die erlangten Erkenntnisse fungieren zudem als Grundlage für ein in der Zukunft avisiertes ML-Projekt des Unternehmens. Es ist daher anzunehmen, dass jene Teilkompetenzen, welche im weiteren Projektverlauf von Relevanz sein werden (TK 3, TK 4, TK 7, TK 8), in höherem Maße als beobachtet steigen werden. Eine Überprüfung zu einem späteren Zeitpunkt war allerdings mit Hinblick auf die unternehmensseitig veranschlagte Dauer des Projekts im Zuge dieser Arbeit nicht möglich.

6.5 Zwischenfazit zur Anwendung und Evaluation

In diesem Kapitel wurde auf Grundlage des Gestaltungsmodells und mittels der Operationalisierungsmethode zunächst ein TAS in Form einer Softwarearchitektur entwickelt. Diese wurde daraufhin in der Programmiersprache Python prototypisch umgesetzt. Das resultierende Softwaresystem leitet Nutzer strukturiert anhand eines Prozessmodells zu einer ersten ML-Lösung und bietet ihnen kontextspezifisch Lerninhalte. Das TAS wurde im Anschluss in zwei Szenarien praktisch zum arbeitsintegrierten Lernen verwendet. Anhand einer randomisierten Kontrollgruppenstudie wurde in einer Lernfabrik ein Vergleich zum Lernen in Form einer klassischen Weiterbildung gezogen. In den Ergebnissen zeigt sich exemplarisch, dass die beteiligten Probanden in höherem Maße in der Lage sind, die Funktionsweise einfacher Algorithmen zu erklären, bereichsübergreifenden Austausch zielorientiert zu gestalten und ML-Projekte strukturiert durchzuführen. Anhand der Anwendung in der industriellen Praxis kann festgehalten werden, dass sich das TAS dazu eignet, einen geeigneten Datensatz zu erstellen und aufgezeichnete Daten mit Hinblick auf physische Ereignisse kausal zu erklären. Zur zukünftigen Verbesserung einer initialen Lösung konnte das TAS zudem einen wichtigen Mehrwert bieten. Weiterführende Erkenntnisse aus der Entwicklung und Anwendung wurden im anschließenden Abschnitt mit Hinblick auf die methodische Durchführung interpretiert.

Die erzielten Ergebnisse der Probandenstudien lassen in der Summe darauf schließen, dass die involvierten Benutzer zufrieden mit dem entwickelten TAS sind (siehe hierzu auch Abschnitt 2.3.3). Außerdem konnte gezeigt werden, dass sie durch die Verwendung des Systems effektiv auf eine sinnvolle Lösung hinarbeiten. So wurden die festgelegten Lernziele in allen Fällen erreicht. Ob und inwiefern die Lösung letztlich effizient ist, kann jedoch keine Aussage getroffen werden. Für Weiterbildungen ist Effizienz mit Hinblick auf die Subjektorientierung jedoch kein gewinnbringendes Kriterium. Darüber hinaus sichern die erlangten Erkenntnisse die Erreichung von FTZ 3.

7 ZUSAMMENFASSUNG UND AUSBLICK

Dieses Kapitel stellt das letzte Kapitel der Arbeit dar und bietet zum einen eine Zusammenfassung der vorgenommenen Entwicklungen (Abschnitt 7.1) und ermöglicht darauf aufbauend einen Ausblick auf zukünftige Forschungsarbeiten (Abschnitt 7.2).

7.1 Zusammenfassung der Arbeit

Die zunehmende Verbreitung von Industrie 4.0-Anwendungen stellt neue Anforderungen an Mitarbeiter in Produktionsumgebungen. Hatten sie in der Vergangenheit oft physische Tätigkeiten zu absolvieren, werden sie in der Zukunft vorrangig kognitive Aufgaben ausführen müssen. Zu diesem Zweck ist es notwendig, aufgenommene Daten auszuwerten und zu interpretieren. Einen Unterstützungsansatz dazu stellen ML-Anwendungen dar. Es zeigt sich aber, dass zur gewinnbringenden Implementierung und Nutzung dieser die notwendigen Kompetenzen unter Anwendern oftmals fehlen. Klassische Weiterbildungen können dabei das bestehende Transferproblem von Theorie zu Praxis nicht adäquat lösen. Hingegen vereinfacht das arbeitsintegrierte Lernen den Transfer von Erlerntem in die betriebliche Anwendung. Hierbei werden Theorieinhalte problembasiert erlernt und können in einem realen Szenario unmittelbar erprobt werden. Einen Ansatz zur praktischen Umsetzung von arbeitsintegriertem Lernen stellen TAS dar. Diese unterstützen das Lernen im Prozess der Arbeit, indem sie die Vermittlung von situativem und arbeitsrelevantem Wissen bereitstellen. Das Forschungsziel der vorliegenden Dissertation ist daher wie folgt:

Das **Ziel der Arbeit** besteht in der systematischen Gestaltung von tutoriellen Assistenzsystemen zur Ermöglichung von arbeitsintegriertem Lernen bei der Einführung von ML-Anwendungen in der Produktion.

Der Stand der Wissenschaft und Technik zeigt dabei, dass bereits eine Vielzahl an Lösungen zur Unterstützung der Integration einer ersten ML-Lösung vorliegen. Diese adressieren wesentliche Schritte einer ML-Pipeline und bilden die Nutzung zur Laufzeit im Produktionsbetrieb ab. Didaktische Überlegungen hingegen werden nur rudimentär berücksichtigt. Bestehende Lösungen fokussieren darüber hinaus vorrangig technische Entwicklungen. Menschzentrierte Aspekte jedoch werden weitestgehend außen vor gelassen. Zur zielführenden Entwicklung von TAS ist es dem entgegenstehend von Relevanz, Anforderungen des maschinellen Lernens, der Entwicklung digitaler Assistenzsysteme und der betrieblichen Weiterbildung zu betrachten sowie einem menschenzentrierten Entwicklungsansatz zu folgen. (siehe Kapitel 2)

Zur Konkretisierung des Forschungsziels der Arbeit wurden drei Forschungsteilziele definiert, welche ein strukturiertes Vorgehen zur Erreichung der Zielstellung erlauben. FTZ 1 befasst sich mit der Konzeption von TAS. Zu dessen Erfüllung sind geeignete Anforderungen zu erheben sowie ein Soll-Modell für TAS zu entwickeln. FTZ 2 fordert eine

systematische Umsetzung des Modells in der Praxis. Hierzu bedarf es folglich eines strukturellen Vorgehens auf Grundlage des Soll-Modells. FTZ 3 stellt schließlich die Effektivität der Lösung in den Vordergrund. So soll überprüft werden, ob mittels dieser ein Mehrwert für die Praxis generiert werden kann. Die erarbeiteten Antworten auf die einzelnen Forschungsteilziele werden unten zusammengefasst. Das Vorgehen innerhalb der Arbeit orientiert sich am Forschungsprozess der Design Research Methodology. (siehe Kapitel 3)

FTZ 1: Entwicklung eines Gestaltungsmodells als konzeptionelle Grundlage eines TAS.

Als konzeptionelle Grundlage des TAS wurde ein Gestaltungsmodell als relevant identifiziert. Für deren Ausgestaltung wurden zunächst anhand einer umfangreichen Literaturrecherche relevante Anforderungen identifiziert. Diese können in inhaltliche und formale Anforderungen untergliedert werden. Die inhaltlichen Anforderungen lassen sich weiter in solche aus der Entwicklung digitaler Assistenzsysteme, in didaktische Aspekte und in ML-spezifische Anforderungen unterteilen. Die ermittelten Anforderungen stellen anschließend Eingangsgrößen des Gestaltungsmodells dar. Dazu wurden sie in Voraussetzungen, Design- und Didaktikkomponenten eingeteilt. Diese wurden ergänzt durch Befähiger, welche das arbeitsintegrierte Lernen unterstützen und im Zuge der Anwendung zum Tragen kommen. In der Summe besteht das Gestaltungsmodell aus 13 Gestaltungskomponenten. Zur Ermittlung von Nutzeranforderungen an die grafische Oberfläche wurde eine Nutzerumfrage ($n = 30$) vorgenommen. FTZ 1 kann mit der Entwicklung des Gestaltungsmodells in Abbildung 20 als erreicht angesehen werden. (siehe Kapitel 4)

FTZ 2: Entwicklung einer Operationalisierungsmethode zur praktischen Anwendung des Gestaltungsmodells.

Damit das konzeptionelle Gestaltungsmodell praktisch verwendet werden kann, wurde weiterhin eine Operationalisierungsmethode entwickelt. Diese basiert auf einem DIN EN ISO-normierten Ordnungsrahmen, welcher für die Gestaltung menschenzentrierter digitaler Systeme geeignet und in der Forschungslandschaft weit verbreitet ist. Die zweite der fünf im Original vorhandenen Phasen wurde mit Hinblick auf die vorherigen Erläuterungen zum Zielbild der Arbeit außen vor gelassen. Die Methode besteht folglich aus vier Phasen. In diese wurden die Subsysteme des Gestaltungsmodells mit ihren jeweiligen Komponenten eingeordnet. So sind zunächst die Voraussetzungen zu erfüllen, bevor Design- und Didaktikkomponenten umgesetzt werden können. Letztlich sind die erarbeiteten Gestaltungslösungen mittels verschiedener Methoden zu evaluieren. Als Ergebnis entsteht eine Softwarearchitektur, welche Grundlage eines in der Praxis anwendbaren Softwaresystems ist. Die Erreichung von FTZ 2 sichert die Methode in Abbildung 30. (siehe Kapitel 5)

FTZ 3: Bewertung des Mehrwerts eines operationalisierten TAS in der betrieblichen Praxis, insbesondere im Vergleich zu einer klassischen Weiterbildung.

Anhand der Operationalisierungsmethode wurde daraufhin das Gestaltungsmodell zu einer Softwarearchitektur überführt und diese anschließend prototypisch in einem Softwaresystem umgesetzt. Dieses führt Nutzer systematisch durch ein Prozessmodell und bietet Ansätze zum non-formalen und informellen Lernen. Mittels zweier Nutzerstudien ($n_1 = 9, n_2 = 13$) wurden im Zuge der Unterstützungsevaluation auf Grundlage des Technology Acceptance Model entwickelte Prototypen hinsichtlich Stärken und Entwicklungspotenzialen überprüft. Die letztlich erzeugte Lösung fand zur Erfolgsevaluation Einzug in zwei Anwendungsszenarien. Dabei wurde zum einen der generierte Mehrwert gegenüber einer klassischen Weiterbildung überprüft. Zu diesem Zweck wurde eine randomisierte Kontrollgruppenstudie ($n = 30$) in einer Lernfabrik durchgeführt. Die Ergebnisse zeigen, dass die Probanden der Experimentalgruppe einen höheren Zuwachs hinsichtlich der Fähigkeit, die Funktionsweise einfacher Algorithmen zu erklären, bereichsübergreifenden Austausch zu gestalten und ML-Projekte strukturiert anzuwenden, erfahren haben. Im Kontrast konnte die Kontrollgruppe im Pre-Post-Vergleich besser Anwendungsfälle für ML-Lösungen aufzählen und auf eine Produktionsumgebung anwenden. Zum anderen lässt sich anhand der Anwendung in einem Industrieszenario ein Mehrwert in der industriellen Praxis festhalten. So konnten die Nutzer im Pre-Post-Vergleich insbesondere ein ML-Projekt strukturierter durchführen, einen geeigneten Datensatz erstellen und diesen besser interpretieren. Letztlich wurden mit dem Ziel der Anwendungsevaluation Probanden- und Expertenbefragungen ($n_{\text{Probanden}} = n_{\text{Experten}} = 17$) durchgeführt und somit die Einhaltung der definierten Anforderungen überprüft. Von den in Summe 22 gestellten Anforderungen können nach Auswertung der Studienergebnisse 20 als erfüllt angesehen werden. FTZ 3 gilt damit als erfüllt. (siehe Kapitel 6)

7.2 Ausblick auf zukünftige Forschungsarbeiten

Aus den gewonnenen Erkenntnissen unter Berücksichtigung der in Abschnitt 3.3 getroffenen Einschränkungen lassen sich Forschungspotenziale ableiten, welche in der Folge erörtert werden.

Weiterentwicklungen des Gestaltungsmodells und der Methode

Der Fokus der vorliegenden Arbeit lag auf der Weiterbildung von Prozessverantwortlichen und operativen Teamleitern, sodass diese in Folge zu Citizen Data Scientists werden. Ob die entwickelten Lösungen auch auf andere Zielgruppen übertragbar sind, konnte nicht untersucht werden. In zukünftigen Arbeiten kann eine zusätzliche Komponente zur Zielgruppendefinition in das Gestaltungsmodell integriert werden, um beispielsweise Produktionsmitarbeiter oder das Top-Management einzubeziehen. In diesem Fall muss zudem die Operationalisierungsmethode um eine zusätzliche Phase zur Zielgruppendefinition erweitert werden. Diese könnte in der ausgelassenen zweiten Phase der zugrunde liegenden Norm vorgenommen werden.

Weiterhin kann die Methode um Schritte zur Softwareentwicklung ergänzt werden. Dies würde die Umsetzung der resultierenden Softwarearchitektur unterstützen. Zu inkludierende Anforderungen liefert exemplarisch die International Organization for Standardization (2023). Letztlich ist die Ergänzung von Ansätzen der erklärbaren künstlichen Intelligenz möglich. Dessen Ziel ist die Interpretierbarkeit von verwendeten Modellen zu erhöhen und sicherzustellen, dass Ergebnisse und Daten den Mitarbeitern in nichttechnischer Sprache erklärt werden (Zhong und Goel 2024). Dies stärkt in der Folge die menschenzentrierte Gestaltung.

Ausweitung des Nutzungskontexts

Die vorliegende Arbeit konzentriert sich wie beschrieben auf Lösungen für das Supervised und Unsupervised Learning. Von Relevanz ist perspektivisch die Überprüfung auf Anwendung in anderen Anwendungsfällen (zum Beispiel Reinforcement Learning und Large Language Models). Es ist anzunehmen, dass eine entsprechende Generalisierbarkeit der bestehenden Lösungen möglich ist. Aus forschungsökonomischen Gründen konnte dies jedoch nicht überprüft werden.

In Abschnitt 3.3 wurde weiterführend erläutert, dass das vorliegende Gestaltungsmodell lediglich zur Konzeptionierung einer ersten ML-Lösung geeignet sein soll, nicht aber zu deren kontinuierlicher Verwendung im Betrieb. Es bedarf daher zukünftig einer Konkretisierung jener Schritte eines Prozessmodells, welche sich auf die langfristige Umsetzung im Betrieb fokussieren. Etwaige weitere Industrieanforderungen sollten dazu ermittelt und ebenso umgesetzt werden.

Anwendung der Lösungen im Feld

Wie dargestellt wurde das TAS in zwei Szenarien (Lernfabrik und Industrieunternehmen) angewendet. In beiden Fällen konnte nur auf kleine Probandenstichproben zurückgegriffen werden. Zur Festigung der beschriebenen Erkenntnisse sollten die erarbeiteten Lösungen daher in größerem Umfang und insbesondere in weiteren Industrieunternehmen angewendet werden. Zur Sicherung, ob die beschriebene Kompetenzentwicklung langfristig anhält und sich die einhergehende Performanz auch in tatsächlichen Industrieprojekten zeigt, sollte weiterhin eine Langzeitbeobachtung vorgenommen werden, beispielsweise nach sechs bis zwölf Monaten (Deutsches Institut für Normung 2019a).

Integration intelligenter Funktionen

Abschnitt 2.3.2 führte kurz in intelligente tutorielle Systeme (ITS) ein. Diese haben zum Ziel, Nutzern personalisiertes Lernen zu ermöglichen und bei dem Aufbau individueller Kompetenzen zu unterstützen. Ein dabei vielversprechender Ansatz, welcher insbesondere in den letzten Jahren an Bedeutung gewinnt, ist die Integration großer Sprachmodelle. Die erarbeiteten Lösungen dieser Dissertation können folglich als Grundlage für die Gestaltung von ITS dienen. Möglich ist darüber hinaus, diese mit Learning Analytics Funktionen zu versehen, sodass Lernfortschritte detailliert ausgewertet werden können.

8 LITERATURVERZEICHNIS

Abel, Markus; Czajkowski, Stefan; Faatz, Laura; Metternich, Joachim; Tenberg, Ralf (2013): Kompetenzorientiertes Curriculum für Lernfabriken. In: *wt* 103 (3), S. 240–245. DOI: 10.37544/1436-4980-2013-3-240.

Abele, Eberhard; Metternich, Joachim; Tenberg, Ralf; Tisch, Michael; Abel, Markus; Hertle, Christian et al. (2015a): Innovative Lernmodule und -fabriken – Validierung und Weiterentwicklung einer neuartigen Wissensplattform für die Produktionsexzellenz von morgen. Hg. v. Technische Universität Darmstadt.

Abele, Eberhard; Metternich, Joachim; Tisch, Michael; Chryssolouris, George; Sihn, Wilfried; ElMaraghy, Hoda et al. (2015b): Learning Factories for Research, Education, and Training. In: *Procedia CIRP* 32, S. 1–6. DOI: 10.1016/j.procir.2015.02.187.

Abele, Eberhard; Metternich, Joachim; Tisch, Michael; Kreß, Antonio (2024): Learning Factories. Featuring New Concepts, Guidelines, Worldwide Best-Practice Examples. 2. Aufl. Cham: Springer.

acatech (2016): Kompetenzen für Industrie 4.0. Qualifizierungsbedarfe und Lösungsansätze. acatech Position. Unter Mitarbeit von Herbert Utz Verlag. Hg. v. acatech - Deutsche Akademie der Technikwissenschaften. München.

Aggogeri, Francesco; Pellegrini, Nicola; Tagliani, Franco Luis (2021): Recent Advances on Machine Learning Applications in Machining Processes. In: *Applied Sciences* 11 (18), S. 8764. DOI: 10.3390/app11188764.

Alpar, Paul; Schulz, Michael (2022): More Data Analysis with Citizen Data Scientists? In: Alvaro Rocha, Hojjat Adeli, Gintautas Dzemyda und Fernando Moreira (Hg.): *Information Systems and Technologies*. WorldCIST. 1. Aufl. Cham: Springer International Publishing (Lecture Notes in Networks and Systems, 469), S. 122–130. DOI: 10.1007/978-3-031-04819-7_13.

Alpaydın, Ethem (2022): *Maschinelles Lernen*. 3. Aufl. Berlin, Boston: De Gruyter Oldenbourg (De Gruyter Studium).

Altman, Douglas G. (1999): *Practical statistics for medical research*. Boca Raton, USA: Chapman & Hall/CRC.

Amershi, Saleema; Weld, Dan; Vorvoreanu, Mihaela; Fourney, Adam; Nushi, Besmira; Collisson, Penny et al. (2019): Guidelines for Human-AI Interaction. In: Stephen Brewster (Hg.): *Proceedings of the Conference on Human Factors in Computing Systems*. Glasgow. ACM Special Interest Group on Computer-Human Interaction. New York: Association for Computing Machinery (ACM Digital Library), S. 1–13. DOI: 10.1145/3290605.3300233.

Anderson, John R. (2013): The Architecture of Cognition. Hoboken: Taylor and Francis.

Anderson, Lorin W.; Krathwohl, David R.; Airasian, Peter W.; Cruikshank, Kathleen, A.; Mayer, Richard E.; Pintrich, Paul R. et al. (2001): A taxonomy for learning, teaching, and assessing. A revision of Bloom's taxonomy of educational objectives. New York: Addison Wesley Longman Inc.

André, Elisabeth; Aurich, Jan C.; Bauer, Wilhelm; Bullinger-Hoffmann, Angelika; Heister, Michael; Huchler, Norbert et al. (2021a): Kompetenzentwicklung für KI. Veränderungen, Bedarfe und Handlungsoptionen. Whitepaper aus der Plattform Lernende Systeme. Hg. v. Lernende Systeme - die Plattform für Künstliche Intelligenz. acatech - Deutsche Akademie der Technikwissenschaften. München.

André, Elisabeth; Bauer, Wilhelm; Braun, Martin; Dang, Chi-Tai; Peissner, Matthias; Weitz, Katharina (2021b): KI-Kompetenzentwicklung bei Sach- und Produktionsarbeit. Projektbericht aus der Plattform Lernende Systeme. Hg. v. Lernende Systeme - die Plattform für Künstliche Intelligenz. acatech - Deutsche Akademie der Technikwissenschaften. München.

Andrianakos, George; Dimitropoulos, Nikos; Michalos, George; Makris, Sotirios (2019): An approach for monitoring the execution of human based assembly operations using machine learning. In: *Procedia CIRP* 86, S. 198–203. DOI: 10.1016/j.procir.2020.01.040.

Angulo, Cecilio; Chacón, Alejandro; Ponsa, Pere (2023): Towards a cognitive assistant supporting human operators in the Artificial Intelligence of Things. In: *Internet of Things* 21, Artikel 100673. DOI: 10.1016/j.iot.2022.100673.

Apt, Wenke; Bovenschulte, Marc; Hartmann, Ernst Andreas; Wischmann, Steffen (2016): Foresight-Studie „Digitale Arbeitswelt“. Forschungsbericht 463. Hg. v. Bundesministerium für Arbeit und Soziales und Institut für Innovation und Technik. Berlin.

Apt, Wenke; Bovenschulte, Marc; Priesack, Kai; Weiß, Christine; Hartmann, Ernst Andreas (2018a): Einsatz von digitalen Assistenzsystemen im Betrieb. Forschungsbericht 502. Hg. v. Bundesministerium für Arbeit und Soziales. Institut für Innovation und Technik. Berlin.

Apt, Wenke; Schubert, Michael; Wischmann, Steffen (2018b): Digitale Assistenzsysteme. Perspektiven und Herausforderungen für den Einsatz in Industrie und Dienstleistungen. Unter Mitarbeit von Institut für Innovation und Technik. Hg. v. VDI/VDE Innovation + Technik GmbH. Berlin.

Aronson, Elliot; Patnoe, Shelley (1997): The jigsaw classroom. Building cooperation in the classroom. 2. Aufl. New York: Longman.

- Austerjost, Maximilian; Hegmanns, Tobias; Kuhn, Axel (2016): Beitrag einer nutzungsabhängigen Instandhaltung zur Planung von Leistungsverfügbarkeit. In: *Logistics Journal: Proceedings*. DOI: 10.2195/lj_Proc_austerjost_de_201602_01.
- Azevedo, Américo L.; Almeida, António H. (2021): Grasp the Challenge of Digital Transition in SMEs. A Training Course Geared towards Decision-Makers. In: *Education Sciences* 11 (4), Artikel 151. DOI: 10.3390/educsci11040151.
- Azevedo, Ana; Santos, Manuel Filipe (2008): KDD, SEMMA and CRISP-DM: A parallel overview. In: *IADIS European Conference on Data Mining*, S. 182–185.
- B&R Industrie Elektronik (2025): Powerlink. Technologie. Hg. v. ABB Group. Friedberg. Online verfügbar unter <https://www.br-automation.com/de-de/technologie/powerlink/technologie/>, zuletzt geprüft am 26.02.2025.
- Babel, Wolfgang (2023): Grundlegende Struktur für IoT – Die Automatisierungspyramide von 1985. In: Wolfgang Babel (Hg.): *Internet of Things und Industrie 4.0*. 1. Aufl. Wiesbaden: Springer Fachmedien; Springer Vieweg, S. 21–30. DOI: 10.1007/978-3-658-39901-6_5.
- Bader, Andreas; Kopp, Oliver; Falkenthal, Michael (2017): Survey and Comparison of Open Source Time Series Databases. In: Bernhard Mitschang, Norbert Ritter, Holger Schwarz, Meike Klettke, Andreas Thor, Oliver Kopp und Matthias Wieland (Hg.): *Datenbanksysteme für Business, Technologie und Web*. Bonn: Gesellschaft für Informatik e.V. (266), S. 249–268.
- Bahl, Anke; Dietzen, Agnes (Hg.) (2019): *Work-based Learning as a Pathway to Competence-based Education. A UNEVOC Network Contribution*. 1. Aufl. Bonn: Federal Institute for Vocational Education and Training (Vocational education and training reports, 27).
- Balzert, Helmut (2011): Was ist eine Softwarearchitektur? In: Helmut Balzert, Peter Liggesmeyer und Holger Schwichtenberg (Hg.): *Lehrbuch der Softwaretechnik. Entwurf, Implementierung, Installation und Betrieb*. 3. Aufl. Heidelberg: Spektrum Akademischer Verlag (Lehrbücher der Informatik), S. 23–27. DOI: 10.1007/978-3-8274-2246-0_6.
- Bardy, Sebastian; Cibis, Katharina; Hoppe, Sophie; Schubert, Tobias; Szuppa, Stephan; Pinzone, Marta et al. (2021): Human in the AI Loop: Teaching Shop Floor Workers Artificial Intelligence in Production. In: *SSRN Journal*. DOI: 10.2139/ssrn.3862568.
- Barrows, Howard S. (1996): Problem-based learning in medicine and beyond: A brief overview. In: *New Directions for Teaching and Learning* 1996 (68), S. 3–12. DOI: 10.1002/tl.37219966804.
- Bauer, Markus; van Dinther, Clemens; Kiefer, Daniel (2020): Machine learning in SME: an empirical study on enablers and success factors. In: *AMCIS 2020 proceedings*

- Advancings in information systems research, Bd. 3. 26th Americas Conference on Information Systems. Atlanta: Association for Information Systems (AIS), S. 1–10.

Bauer, Nadja; Stankiewicz, Lukas; Jastrow, Malte; Horn, Daniel; Teubner, Jens; Kersting, Kristian et al. (2018): Industrial Data Science: Developing a Qualification Concept for Machine Learning in Industrial Production. In: *Archives of Data Science, Series A* 5 (1), Artikel P27. DOI: 10.5445/KSP/1000087327/27.

Becker, Jörg; Probandt, Wolfgang; Vering, Oliver (2012): Grundsätze ordnungsmäßiger Modellierung. Konzeption und Praxisbeispiel für ein effizientes Prozessmanagement. Berlin, Heidelberg: Springer Berlin Heidelberg (BPM kompetent).

Begovic, Advan (2018): Datenbasiertes Wissensmanagement für Smart Services im Werkzeugbau. Dissertation. Rheinisch-Westfälische Technische Hochschule Aachen; Apprimus Verlag.

Beiß, Tobias; Klapic, Edin; Hardt, Tina; Schwenken, Jörn; Deuse, Jochen (2024): Potenzialanalyse industrieller Datenanalysen in der Produktion am Beispiel des Kunststoffschweißens. In: Jochen Deuse, Ralf Klinkenberg und Nikolai West (Hg.): Industrielle Datenanalyse. Entwicklung einer Datenanalyse-Plattform für die wertschaffende, kompetenzorientierte Kollaboration in dynamischen Wertschöpfungsnetzwerken. Wiesbaden, Heidelberg: Springer Vieweg, S. 133–143. DOI: 10.1007/978-3-658-42779-5_12.

Berekoven, Ludwig; Eckert, Werner; Ellenrieder, Peter (2009): Marktforschung. Methodische Grundlagen und praktische Anwendung. 12. Aufl. Wiesbaden: Gabler (Gabler-Lehrbuch).

Bergmann, Bärbel (1999): Training für den Arbeitsprozess. Entwicklung und Evaluation aufgaben- und zielgruppenspezifischer Trainingsprogramme. Zürich: vdf Hochschulverlag an der ETH Zürich (Mensch, Technik, Organisation, 21).

Bhosale, Sachin Shankar; Pujari, Vinayak; Multani, Zameer (2020): Advantages and Disadvantages of Artificial Intelligence. In: Aayushi International Interdisciplinary Research Journal (Hg.): National Seminar on "Trends in Geography, Commerce, IT And Sustainable Development". Khed, Ratnagiri, Maharashtra. 77. Aufl., S. 227–230.

Bianchini, Marco; Michalkova, Veronika (2019): Data Analytics in SMEs. Trends and Policies. Hg. v. Organisation für wirtschaftliche Zusammenarbeit und Entwicklung (OECD) (OECD SME and Entrepreneurship Papers, 15).

Biegel, Tobias; Bretones Cassoli, Beatriz; Hoffmann, Felix; Jourdan, Nicolas; Metternich, Joachim (2021): An AI Management Model for the Manufacturing Industry - AIMM. Hg. v. Universitäts- und Landesbibliothek Darmstadt. Darmstadt. DOI: 10.26083/TUPRINTS-00019038.

Bigalk, Debora (2006): Lernförderlichkeit von Arbeitsplätzen - Spiegelbild der Organisation? Eine vergleichende Analyse von Unternehmen mit hoch und gering

lernförderlichen Arbeitsplätzen. Kassel: Kassel University Press (Schriftenreihe Personal- und Organisationsentwicklung, 3).

Bilogur, Aleksey (2018): Missingno: a missing data visualization suite. In: *Journal of Open Source Software* 3 (22), S. 547. DOI: 10.21105/joss.00547.

Bishop, Christopher M. (2006): Pattern recognition and machine learning. New York: Springer Science & Business Media LLC (Information Science and Statistics).

Bitkom (2014): Big-Data-Technologien. Wissen für Entscheider. Hg. v. Bundesverband Informationswirtschaft, Telekommunikation und neue Medien. Berlin. Online verfügbar unter <https://www.bitkom.org/sites/default/files/file/import/140228-Big-Data-Technologien-Wissen-fuer-Entscheider.pdf>, zuletzt geprüft am 27.02.2025.

Bitkom Research (2022): Welche Bedeutung hat Industrie 4.0 für Ihr Unternehmen? Hg. v. Statista GmbH. Statista GmbH. Berlin. Online verfügbar unter <https://de.statista.com/statistik/daten/studie/830769/umfrage/bedeutung-von-industrie-40-in-deutschland/>, zuletzt geprüft am 28.01.2025.

Blessing, Lucienne T. M.; Chakrabarti, Amaresh (2009): DRM, a Design Research Methodology. London: Springer London Limited.

Bloom, Benjamin Samuel (Hg.) (1956): Taxonomy of educational objectives. The classification of educational goals. New York, London: Longman.

Blumberg, Verena Simone Lore; Kauffeld, Simone (2021): Kompetenzen und Wege der Kompetenzentwicklung in der Industrie 4.0. In: *Gruppe. Interaktion. Organisation. Zeitschrift für Angewandte Organisationspsychologie (GIO)* 52 (2), S. 203–225. DOI: 10.1007/s11612-021-00579-5.

BMBF (2019a): Digitale Zukunft: Lernen. Forschen. Wissen. Die Digitalstrategie des BMBF. Hg. v. Bundesministerium für Bildung und Forschung (BMBF). Berlin. Online verfügbar unter https://www.bildung-forschung.digital/digitalezukunft/shared-docs/Downloads/files/bmbf_digitalstrategie.pdf?__blob=publicationFile&v=3, zuletzt geprüft am 28.01.2025.

BMBF (2019b): Zukunft der Arbeit. Innovationen für die Arbeit von morgen. Hg. v. Bundesministerium für Bildung und Forschung (BMBF). Bonn. Online verfügbar unter https://digital productions/wp-content/uploads/2016/01/zukunft_der_arbeit.pdf, zuletzt geprüft am 23.05.2025.

BMWE (2025): Digitale Transformation in der Industrie. Bundesministerium für Wirtschaft und Energie (BMWE). Berlin. Online verfügbar unter <https://www.bmwk.de/Redaktion/DE/Dossier/industrie-40.html>, zuletzt geprüft am 28.01.2025.

Böde, Eckard; Hartmann, Ernst Andreas; Lüdtkke, Andreas; Oppenheimer, Frank; Rötting, Matthias; Wegerich, Anne (2013): Mensch-Technik-Interaktion. Leitfaden für Hersteller und Anwender. Unter Mitarbeit von Institut für Innovation und Technik. Hg. v. Bundesministerium für Wirtschaft und Technologie. Berlin.

- Bodendorf, Freimut (2006): Daten- und Wissensmanagement. 2. Aufl. Berlin, Heidelberg: Springer (Springer-Lehrbuch).
- Bothof, Alfons (2015): Zukunft der Arbeit im Kontext von Autonomik und Industrie 4.0. In: Alfons Bothof und Ernst Andreas Hartmann (Hg.): Zukunft der Arbeit in Industrie 4.0. Berlin, Heidelberg: Springer Vieweg, S. 3–8. DOI: 10.1007/978-3-662-45915-7_1.
- Bovenschulte, Marc (2020): Kognitive Assistenzsysteme. Hg. v. Büro für Technikfolgen-Abschätzung beim Deutschen Bundestag (TAB). Institut für Technikfolgenabschätzung und Systemanalyse (ITAS). Karlsruhe (Themenkurzprofil, 38). DOI: 10.5445/IR/1000133949.
- Bowman, Doug A.; Kruijff, Ernst; LaViola Jr., Joseph, J.; Poupyrev, Ivan (2011): 3D User Interfaces. Theory and practice. 3. Aufl. Boston, München: Addison-Wesley.
- Brandl, Werner (1997): Lernen als „konstruktiver“ Prozess: Trugbild oder Wirklichkeit? In: *Schulmagazin 5 bis 10: Impulse für kreativen unterricht* 12 (5), S. 53–56.
- Braun, Martin (2018): Digitale Assistenzsysteme. Gestaltungsanforderungen, Klassifikation und Anwendungen. In: *Industrie 4.0 Management* 34 (4), S. 12–14.
- Bray, Tim (2017): The JavaScript Object Notation (JSON) Data Interchange Format. Hg. v. Internet Engineering Task Force (IETF) (Request for Comments, 8259). Online verfügbar unter <https://datatracker.ietf.org/doc/html/rfc8259>, zuletzt geprüft am 28.01.2025.
- Bray, Tim; Paoli, Jean; Sperberg-McQueen, C. M.; Maler, Eve; Yergeau, Francois (2008): Extensible Markup Language (XML). Hg. v. World Wide Web Consortium (W3C Recommendation). Online verfügbar unter <https://www.w3.org/TR/REC-xml/>, zuletzt geprüft am 28.01.2025.
- Brooke, John (1996): SUS: A quick and dirty usability scale. In: Patrick W. Jordan, Bruce Thomas, Bernard A. Weerdmeester und Ian Lyall McClelland (Hg.): Usability evaluation in industry. 1. Aufl. Bristol, London: Taylor and Francis, S. 189–194.
- Broy, Manfred; Kuhrmann, Marco (2021): Anforderungsanalyse und Anforderungsmanagement. In: Manfred Broy und Marco Kuhrmann (Hg.): Einführung in die Softwaretechnik. Berlin, Heidelberg: SpringerVieweg (Xpert.press), S. 199–222. DOI: 10.1007/978-3-662-50263-1_5.
- Burggräf, Peter; Schuh, Günther; Ebade Esfahani, Matthias; Dannapfel, Matthias; Nöcker, Jan; Wesch-Potente, Cathrin (2021): Einführung in die Fabrikplanung. In: Peter Burggräf und Günther Schuh (Hg.): Fabrikplanung. 2. Aufl. Berlin, Heidelberg: Springer Vieweg (Handbuch Produktion und Management, 4), S. 1–62. DOI: 10.1007/978-3-662-61969-8_1.
- Cachay, Jan; Abele, Eberhard (2012): Developing Competencies for Continuous Improvement Processes on the Shop Floor through Learning Factories. Conceptual Design

and Empirical Validation. In: *Procedia CIRP* 3, S. 638–643. DOI: 10.1016/j.procir.2012.07.109.

Cady, Field (2017): The data science handbook. Hoboken, New Jersey: John Wiley & Sons Incorporated (Wiley online library).

Carvalho, Thyago P.; Soares, Fabrizzio A. A. M. N.; Vita, Roberto; Da Francisco, Roberto P.; Basto, João P.; Alcalá, Symone G. S. (2019): A systematic literature review of machine learning methods applied to predictive maintenance. In: *Computers & Industrial Engineering* 137, Artikel 106024. DOI: 10.1016/j.cie.2019.106024.

Cedefop (2016): Europäische Leitlinien für die Validierung nicht formalen und informellen Lernens. Hg. v. Amt für Veröffentlichungen der Europäischen Union. European Centre for the Development of Vocational Education. Luxemburg (Cedefop reference series, 104).

Chancellor, Stevie (2023): Toward Practices for Human-Centered Machine Learning. In: *Communications of the ACM* 66 (3), S. 78–85. DOI: 10.1145/3530987.

Chomsky, Noam (1965): Aspects of the Theory of Syntax. 50. Aufl. Cambridge, Massachusetts: The MIT Press.

Chryssolouris, George; Mavrikios, Dimitris; Mourtzis, Dimitris (2013): Manufacturing Systems: Skills & Competencies for the Future. In: *Procedia CIRP* 7, S. 17–24. DOI: 10.1016/j.procir.2013.05.004.

Cinar, Eyup; Kalay, Sena; Saricicek, Inci (2022): A Predictive Maintenance System Design and Implementation for Intelligent Manufacturing. In: *Machines* 10 (11), Artikel 1006. DOI: 10.3390/machines10111006.

Cohen, Jacob (1968): Weighted kappa: nominal scale agreement with provision for scaled disagreement or partial credit. In: *Psychological bulletin* 70 (4), S. 213–220. DOI: 10.1037/h0026256.

Cordts, Sönke; Blakowski, Gerold; Brosius, Gerhard (2011): Datenbanken für Wirtschaftsinformatiker. Nach dem aktuellen Standard SQL:2008. Wiesbaden: Vieweg & Teubner (SpringerLink Bücher).

Court, David; Perrey, Jesko; McGuire, Tim; Gordon, Jonathan; Spillecke, Dennis (2015): Marketing & Sales. Big Data, Analytics and the future of Marketing & Sales. Hg. v. McKinsey & Company. Online verfügbar unter <https://www.mckinsey.com/~/media/McKinsey/Business%20Functions/Marketing%20and%20Sales/Our%20Insights/EBook%20Big%20data%20analytics%20and%20the%20future%20of%20marketing%20sales/Big-Data-eBook.ashx>, zuletzt geprüft am 28.01.2025.

Daniyan, Ilesanmi; Mpofu, Khumbulani; Oyesola, Moses; Ramatsetse, Boitumelo; Adeodu, Adefemi (2020): Artificial intelligence for predictive maintenance in the railcar

learning factories. In: *Procedia Manufacturing* 45, S. 13–18. DOI: 10.1016/j.promfg.2020.04.032.

Davis, Fred D. (1989): Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. In: *MIS Quarterly* 13 (3), S. 319–340. DOI: 10.2307/249008.

Dehnbostel, Peter (2009): New Learning Strategies and Learning Cultures in Companies. In: Rupert Maclean und David Wilson (Hg.): *International Handbook of Education for the Changing World of Work. Bridging Academic and Vocational Learning*. Dordrecht: Springer, S. 2629–2645. DOI: 10.1007/978-1-4020-5281-1_173.

Dehnbostel, Peter (2015): *Betriebliche Bildungsarbeit. Kompetenzbasierte Aus- und Weiterbildung im Betrieb*. 2. Aufl. Baltmannsweiler: Schneider Verlag Hohengehren (Studententexte Basiscurriculum Berufs- und Wirtschaftspädagogik, 9).

Dehnbostel, Peter (2016): Informelles Lernen in der betrieblichen Bildungsarbeit. In: Matthias Rohs (Hg.): *Handbuch Informelles Lernen*. Wiesbaden: Springer VS (Springer Reference Sozialwissenschaften), S. 343–364. DOI: 10.1007/978-3-658-05953-8_41.

Dehnbostel, Peter (2018a): Der Betrieb als Lernort. In: Maja Apelt, Ingo Bode, Raimund Hasse, Uli Meyer, Victoria von Groddeck, Maximiliane Wilkesmann und Arnold Windeler (Hg.): *Handbuch Organisationssoziologie*. Wiesbaden: Springer VS (Living reference work), S. 1–17. DOI: 10.1007/978-3-658-19372-0_38-1.

Dehnbostel, Peter (2018b): Lern- und kompetenzförderliche Arbeitsgestaltung in der digitalisierten Arbeitswelt. In: *Arbeit* 27 (4), S. 269–294. DOI: 10.1515/arbeit-2018-0022.

Dehnbostel, Peter (2020): Lernorte, Lernräume und Lernarchitekturen in der digitalen Transformation der Arbeit. In: Götz Richter (Hg.): *Lernen in der digitalen Transformation. Wie arbeitsintegriertes Lernen in der betrieblichen Praxis gelingt*. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 19–34.

Dehnbostel, Peter; Schröder, Thomas (2017): Work-based and Work-related Learning. Models and Learning Concepts. In: *TVET@Asia* (9), S. 1–16.

Delbridge, Rick; Lowe, James; Oliver, Nick (2000): Shopfloor Responsibilities Under Lean Teamworking. In: *Human Relations* 53 (11), S. 1459–1479. DOI: 10.1177/00187267005311003.

Delgado, Miguel; Garcia, Antonio; Ortega, Juan Antonio (2011): Evaluation of feature calculation methods for electromechanical system diagnosis. In: *International Symposium on Diagnostics for Electric Machines, Power Electronics & Drives*. Bologna. Institute of Electrical and Electronics Engineers; IEEE Power Electronics Society. Piscataway, New Jersey, S. 495–502. DOI: 10.1109/DEMPED.2011.6063669.

Destatis (2022): *Berufliche Weiterbildung in Unternehmen. Sechste Europäische Erhebung über die berufliche Weiterbildung in Unternehmen (CVTS6)*. Hg. v. Statistisches Bundesamt. Wiesbaden.

Deterding, Sebastian; Dixon, Dan; Khaled, Rilla; Nacke, Lennart (2011): From game design elements to gamefulness. In: Artur Lugmayr, Heljä Franssila, Christian Safran und Imed Hammouda (Hg.): Proceedings of the International Academic MindTrek Conference Envisioning Future Media Environments. Tampere. Association for Computing Machinery; ACM Special Interest Group on Computer-Human Interaction; ACM Special Interest Group on Multimedia. New York, S. 9–15. DOI: 10.1145/2181037.2181040.

Deuse, Jochen; Wöstmann, René; Schulte, Lukas; Panusch, Thorben; Kimberger, Josef (2021): Transdisciplinary competence development for role models in data-driven value creation. The Citizen Data Scientist in the Centre of Industrial Data Science Teams. In: Wilfried Sihm und Sebastian Schlund (Hg.): Competence development and learning assistance systems for the data-driven future. Berlin: GITO Verlag (Schriftenreihe der Wissenschaftlichen Gesellschaft für Arbeits- und Betriebsorganisation e.V), S. 36–56. DOI: 10.30844/wgab_2021_3.

Deutsches Institut für Normung (2017a): DIN EN ISO 9241-112: Ergonomie der Mensch-System-Interaktion, Teil 112: Grundsätze der Informationsdarstellung, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2017b): DIN EN ISO 9241-125: Ergonomie der Mensch-System-Interaktion, Teil 125: Empfehlungen zur visuellen Informationsdarstellung, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2018a): DIN EN ISO 9241-11: Ergonomie der Mensch-System-Interaktion, Teil 11: Gebrauchstauglichkeit, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2018b): DIN EN ISO 13306: Instandhaltung, Begriffe der Instandhaltung, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2019a): DIN EN ISO 9241-210: Ergonomie der Mensch-System-Interaktion, Teil 210: Menschzentrierte Gestaltung interaktiver Systeme, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2019b): DIN 31051: Grundlagen der Instandhaltung, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2020): DIN EN ISO 9241-110: Ergonomie der Mensch-System-Interaktion, Teil 110: Interaktionsprinzipien, Berlin: Beuth Verlag GmbH.

Deutsches Institut für Normung (2022): DIN EN 15341: Instandhaltung, - Wesentliche Leistungskennzahlen für die Instandhaltung, Berlin: DIN Media GmbH.

Deutsches Institut für Normung (2024a): DIN ISO 24495-1: Einfache Sprache - Teil 1: Grundsätze und Leitlinien, Berlin: DIN Media GmbH.

Deutsches Institut für Normung (2024b): DIN EN 13757-2: Kommunikationssysteme für Zähler, Teil 2: Drahtgebundene M-Bus-Kommunikation, Berlin: Beuth Verlag GmbH.

Diamantis, Dimitrios E.; Iakovidis, Dimitris K. (2021): ASML: Algorithm-Agnostic Architecture for Scalable Machine Learning. In: *IEEE Access* 9, S. 51970–51982. DOI: 10.1109/ACCESS.2021.3069857.

Dillenbourg, Pierre (1999): What do you mean by collaborative learning? In: Pierre Dillenbourg (Hg.): *Collaborative Learning. Cognitive and Computational Approaches*. Oxford: Elsevier, S. 1–19.

Dobler, Martin; Meierhofer, Jurg; Frick, Klaus; Bentele, Marcus (2022): On the Use of Low-Code and No-Code Tools for Teaching Data Science in Applied Industrial and University Settings. In: *Technology, engineering, and innovation management communities as enablers for social-ecological transitions. 28th International Conference on Engineering, Technology and Innovation & 31st International Association For Management of Technology*. Nancy. Institute of Electrical and Electronics Engineers. Piscataway, New Jersey, S. 1–8. DOI: 10.1109/ICE/ITMC-IAMOT55089.2022.10033266.

Dobra, Péter; Jósmai, János (2023): Overall Equipment Effectiveness-related Assembly Pattern Catalogue based on Machine Learning. In: *Manufacturing Technology* 23 (3), S. 276–283. DOI: 10.21062/mft.2023.036.

Doltsinis, Stefanos; Ferreira, Pedro; Lohse, Niels (2018): A Symbiotic Human–Machine Learning Approach for Production Ramp-up. In: *IEEE Transactions on Human-Machine Systems* 48 (3), S. 229–240. DOI: 10.1109/THMS.2017.2717885.

Döring, Nicola (2022): *Forschungsmethoden und Evaluation in den Sozial- und Humanwissenschaften*. 6. Aufl. Berlin, Heidelberg: Springer.

Dreyfus, Stuart E.; Dreyfus, Hubert L. (1980): *A five-staged model of the mental activities involved in directed skill acquisition*. Unter Mitarbeit von Air Force Office of Scientific Research. Hg. v. California University Berkeley Operations Research Center. Berkeley.

Duden (2024a): *Fähigkeit*. Hg. v. Cornelsen Verlag. Online verfügbar unter <https://www.duden.de/rechtschreibung/Faehigkeit>, zuletzt geprüft am 28.01.2025.

Duden (2024b): *Methode*. Hg. v. Cornelsen Verlag. Online verfügbar unter <https://www.duden.de/rechtschreibung/Methode>, zuletzt geprüft am 28.01.2025.

Dyer, Andrew; Barybkina, Elena; Erker, Patrick; Sullivan, Jeff (2018): *How Learning Contracts Can Drive an Industrious Revolution*. BCG Henderson Institute. Online verfügbar unter <https://www.bcg.com/publications/2018/how-learning-contracts-can-drive-industrious-revolution>, zuletzt geprüft am 28.01.2025.

ECMA International (2017): The JSON Data Interchange Syntax. Genf. Online verfügbar unter https://ecma-international.org/wp-content/uploads/ECMA-404_2nd_edition_december_2017.pdf, zuletzt geprüft am 24.02.2025.

Eder, Matthias; Hulla, Maria; Auer, Felix; Ramsauer, Christian (2021): Interactive Teaching Concept for a Data Analytics Workshop in Learning Factories. In: *SSRN Journal*. DOI: 10.2139/ssrn.3858471.

Effrosynidis, Dimitris (2020): Normalization and Standardization in 2 Minutes. Hg. v. Towards Data Science. Online verfügbar unter <https://towardsdatascience.com/normalization-and-standardization-in-2-minutes-e0609a01e76>, zuletzt geprüft am 28.01.2025.

Elattar, Hatem M.; Elminir, Hamdy K.; Riad, A. M. (2016): Prognostics: a literature review. In: *Complex & Intelligent Systems* 2, S. 125–154. DOI: 10.1007/s40747-016-0019-3.

Elshaw, Radwa; Maher, Mohamed; Sakr, Sherif (2019): Automated Machine Learning: State-of-The-Art and Open Challenges. Online verfügbar unter <http://arxiv.org/pdf/1906.02287>, zuletzt geprüft am 28.01.2025.

Engels, Dietrich (2016): Chancen und Risiken der Digitalisierung der Arbeitswelt für die Beschäftigung von Menschen mit Behinderung. Forschungsbericht 467. Hg. v. Bundesministerium für Arbeit und Soziales und ISG - Institut für Sozialforschung und Gesellschaftspolitik. Köln.

Enke, Judith; Tisch, Michael; Metternich, Joachim (2016): A guide to develop competency-oriented Lean Learning Factories systematically. In: 3rd European LEAN EDUCATOR Conference. ELEC 2016. Buckingham. University of Buckingham.

Ermakova, Tatiana; Blume, Julia; Fabian, Benjamin; Fomenko, Elena; Berlin, Marcus; Hauswirth, Manfred (2021): Beyond the Hype: Why Do Data-Driven Projects Fail? In: Tung Bui (Hg.): Proceedings of the 54th Hawaii International Conference on System Sciences. Hawaii International Conference on System Sciences, S. 5081–5090. DOI: 10.24251/HICSS.2021.619.

Erpenbeck, John; Rosenstiel, Lutz; Grote, Sven; Sauter, Werner (2017): Handbuch Kompetenzmessung. Erkennen, verstehen und bewerten von Kompetenzen in der betrieblichen, pädagogischen und psychologischen Praxis. Unter Mitarbeit von Lutz Rosenstiel, Sven Grote und Werner Sauter. 3. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH.

Erpenbeck, John; Sauter, Simon; Sauter, Werner (2016): Social Workplace Learning. Kompetenzentwicklung im Arbeitsprozess und im Netz in der Enterprise 2.0. 1. Aufl. Wiesbaden: Springer Gabler (SpringerLink Bücher).

Erpenbeck, John; Sauter, Werner (2013): So werden wir lernen! Kompetenzentwicklung in einer Welt fühlender Computer, kluger Wolken und sinnsuchender Netze. Berlin, Heidelberg: Springer Gabler.

Ethnologue (2024): Anzahl der Sprecher (Muttersprache oder Zweitsprache) im Jahr 2024. Hg. v. Statista GmbH. Online verfügbar unter <https://de.statista.com/statistik/daten/studie/150407/umfrage/die-zehn-meistgesprochenen-sprachen-weltweit/>, zuletzt geprüft am 28.01.2025.

Europäische Kommission (2020): Aktionsplan für digitale Bildung 2021-2027. Neuauflage des Bildungswesens für das digitale Zeitalter. Hg. v. Europäische Kommission. Brüssel. Online verfügbar unter <https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:52020DC0624>, zuletzt geprüft am 28.01.2025.

Europäisches Parlament; Rat der Europäischen Union (2008): Empfehlung des Europäischen Parlaments und des Rates vom 23. April 2008 zur Einrichtung des Europäischen Qualifikationsrahmens für lebenslanges Lernen. Hg. v. Amt für Veröffentlichungen der Europäischen Union. Online verfügbar unter [https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:32008H0506\(01\)&from=DE](https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:32008H0506(01)&from=DE), zuletzt geprüft am 28.01.2025.

Eusterwiemann, Tobias; Eiling, Florian; Gauger, Isabelle; Bildstein, Andreas (2021): An Integration Approach of Educational Artificial Intelligence (AI) Use Cases Into a Demonstration Factory. In: *SSRN Journal*. DOI: 10.2139/ssrn.3862399.

Fahle, Simon; Kuhlenkötter, Bernd; Bülow, Florian; Thewes, Felix; Prinz, Christopher; Meske, Christian (2022): Conceptual Design and Implementation of Training Scenarios for Human-Centered Artificial Intelligence in Learning Factories. In: *SSRN Journal*. DOI: 10.2139/ssrn.4072322.

Farooqui, Ashfaq; Bengtsson, Kristofer; Falkman, Petter; Fabian, Martin (2019): From factory floor to process models: A data gathering approach to generate, transform, and visualize manufacturing processes. In: *CIRP Journal of Manufacturing Science and Technology* 24, S. 6–16. DOI: 10.1016/j.cirpj.2018.12.002.

Fayyad, Usama M.; Piatetsky-Shapiro, Gregory; Smyth, Padhraic (1996): From Data Mining to Knowledge Discovery in Databases. In: *AI Magazine* 17 (3), Artikel 37.

Fleiss, Joseph L.; Cohen, Jacob (1973): The Equivalence of Weighted Kappa and the Intraclass Correlation Coefficient as Measures of Reliability. In: *Educational and Psychological Measurement* 33 (3), S. 613–619. DOI: 10.1177/001316447303300309.

Franken, Swetlana; Mauritz, Nina; Prädikow, Lotte (2022): Kompetenzen für KI-Anwendungen: Theoretisches Modell und partizipative Erfassung und Vermittlung in Unternehmen. In: Gesellschaft für Arbeitswissenschaft e.V. (Hg.): Frühjahrskongress 2022. Technologie und Bildung in hybriden Arbeitswelten, B.8.10. Magdeburg.

Frick, Nicholas Uwe (2024): Integration des Digitalen Zwillings in das Wertstrommanagement. Dissertation. Technische Universität Darmstadt, Darmstadt.

- Friebe, Judith (2005): Merkmale unternehmensbezogener Lernkulturen und ihr Einfluss auf die Kompetenzen der Mitarbeiter. Dissertation. Ruprecht-Karls-Universität Heidelberg, Heidelberg.
- Gabriel, Stefan; Falkowski, Tommy; Graunke, Jannis; Dumitrescu, Roman; Murrenhoff, Anike; Kretzschmer, Veronika; Hompel, Michael ten (2024): Künstliche Intelligenz und industrielle Arbeit - Perspektiven und Gestaltungsoptionen. Hg. v. acatech - Deutsche Akademie der Technikwissenschaften. München.
- Garouani, Moncef; Ahmad, Adeel; Bouneffa, Mourad; Hamlich, Mohamed; Bourguin, Gregory; Lewandowski, Arnaud (2022): Towards big industrial data mining through explainable automated machine learning. In: *The International Journal of Advanced Manufacturing Technology* 120 (1-2), S. 1169–1188. DOI: 10.1007/s00170-022-08761-9.
- Gartner Inc. (2017): Gartner Says More Than 40 Percent of Data Science Tasks Will Be Automated by 2020. Analysts to Explore Trends in Data Science at Gartner Data & Analytics Summits 2017. Sydney, Australien. Moore, Susan. Online verfügbar unter <https://www.gartner.com/en/newsroom/press-releases/2017-01-16-gartner-says-more-than-40-percent-of-data-science-tasks-will-be-automated-by-2020>, zuletzt geprüft am 28.01.2025.
- Gay, Antonin; Voisin, Alexandre; Iung, Benoit; Do, Phuc; Bonidal, Rémi; Khelassi, Ahmed (2022): Data Augmentation-based Prognostics for Predictive Maintenance of Industrial System. In: *CIRP Annals* 71 (1), S. 409–412. DOI: 10.1016/j.cirp.2022.04.005.
- Géron, Aurélien (2019): Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. Concepts, tools, and techniques to build intelligent systems. 2. Aufl. Peking, Boston, Farnham, Sebastopol, Tokio: O'Reilly.
- Gholamy, Afshin; Kreinovich, Vladik; Kosheleva, Olga (2018): Why 70/30 or 80/20 Relation Between Training and Testing Sets. A Pedagogical Explanation. Hg. v. Departmental Technical Reports. El Paso. Online verfügbar unter https://scholarworks.utep.edu/cgi/viewcontent.cgi?article=2202&context=cs_techrep, zuletzt geprüft am 28.01.2025.
- Giarratano, Joseph C.; Riley, Gary (2005): Expert systems. Principles and programming. 4. Aufl. Boston: Thomson Course Technology.
- Ginns, Paul (2005): Meta-analysis of the modality effect. In: *Learning and Instruction* 15 (4), S. 313–331. DOI: 10.1016/j.learninstruc.2005.07.001.
- Glass, Rupert (2021): Methodik zur multivariaten Messung fachlich-methodischer Kompetenzen für die Produktion. Dissertation. Technische Universität Darmstadt; Shaker Verlag.
- Goldstein, Markus; Uchida, Seiichi (2016): A Comparative Evaluation of Unsupervised Anomaly Detection Algorithms for Multivariate Data. In: *PloS one* 11 (4), e0152173. DOI: 10.1371/journal.pone.0152173.

Gorecky, Dominic; Mura, Katharina; Arlt, Frank (2013): A Vision on Training and Knowledge Sharing Applications in Future Factories. In: *IFAC Proceedings Volumes* 46 (15), S. 90–97. DOI: 10.3182/20130811-5-US-2037.00019.

Graf, Nele; Edelkraut, Frank (2016): Mentoring. Das Praxisbuch für Personalverantwortliche und Unternehmer. 2. Aufl. Wiesbaden: Springer Fachmedien.

Graham, Patrick; Jackson, Rodney (1993): The analysis of ordinal agreement data: beyond weighted kappa. In: *Journal of Clinical Epidemiology* 46 (9), S. 1055–1062. DOI: 10.1016/0895-4356(93)90173-X.

Grandi, Fabio; Zanni, Luca; Peruzzini, Margherita; Pellicciari, Marcello; Campanella, Claudia Elisabetta (2020): A Transdisciplinary digital approach for tractor’s human-centred design. In: *International Journal of Computer Integrated Manufacturing* 33 (4), S. 377–397. DOI: 10.1080/0951192X.2019.1599441.

Gutschow, Katrin (2020): Validierung und Anerkennung informell erworbener Kompetenzen. In: Rolf Arnold, Antonius Lipsmeier und Matthias Rohs (Hg.): *Handbuch Berufsbildung*. Mit 53 Abbildungen und 19 Tabellen. 3. Aufl. Wiesbaden: Springer VS (Springer Reference), S. 455–470. DOI: 10.1007/978-3-658-19312-6_36.

Haberfellner, Reinhard; Weck, Olivier L. de; Fricke, Ernst; Vössner, Siegfried (Hg.) (2015): *Systems engineering. Grundlagen und Anwendung*. 13. Aufl. Zürich: Orell Füssli Verlag.

Hacker, Winfried (2015): *Lern-, gesundheits- und leistungsförderliche Arbeitsgestaltung in kleinen und mittleren Unternehmen - Warum und wie?* Dresden: Sächsische Landesbibliothek- Staats- und Universitätsbibliothek Dresden (Projektberichte, 86).

Hahne, Klaus (2003): Zur Bedeutung der Arbeit in Lernkonzepten der beruflichen Bildung. Ein vergleichender Blick auf die Entwicklungen in Industrie und Handwerk. In: *Berufsbildung in Wissenschaft und Praxis* (1), S. 29–34.

Haman, Marcus Karl (2013): *Rollen & Verantwortlichkeiten in der Produktion. Produktionsmanagement für Führungskräfte*. Norderstedt: Books on Demand.

Hambach, Jens (2019): *Methodik für einen digitalen Verbesserungsprozess im betrieblichen KVP. Entwicklung und problemorientierte Validierung*. Dissertation. Technische Universität Darmstadt, Darmstadt.

Hansen, Emil Blixt; Bøgh, Simon (2021): Artificial intelligence and internet of things in small and medium-sized enterprises: A survey. In: *Journal of Manufacturing Systems* 58, S. 362–372. DOI: 10.1016/j.jmsy.2020.08.009.

Härder, Theo; Rahm, Erhard (2001): *Datenbanksysteme. Konzepte und Techniken der Implementierung*. 2. Aufl. Berlin, Heidelberg: Springer (Springer eBook Collection Computer Science and Engineering).

- Hardt, Tina; Mieves, Hans-Joachim; Marx, Christoph; Meisberger, Christian (2024): Retrofitting und Datenakquisition mittels Industrie 4.0-Technologien. In: Jochen Deuse, Ralf Klinkenberg und Nikolai West (Hg.): Industrielle Datenanalyse. Entwicklung einer Datenanalyse-Plattform für die wertschaffende, kompetenzorientierte Kollaboration in dynamischen Wertschöpfungsnetzwerken. Wiesbaden, Heidelberg: Springer Vieweg, S. 155–162. DOI: 10.1007/978-3-658-42779-5_14.
- Hartley, J. Roger; Sleeman, D. H. (1973): Towards more intelligent teaching systems. In: *International Journal of Man-Machine Studies* 5 (2), S. 215–236. DOI: 10.1016/S0020-7373(73)80033-1.
- Hartmann, Ernst Andreas (2015): Arbeitsgestaltung für Industrie 4.0: Alte Wahrheiten, neue Herausforderungen. In: Alfons Botthof und Ernst Andreas Hartmann (Hg.): Zukunft der Arbeit in Industrie 4.0. Berlin, Heidelberg: Springer Vieweg, S. 9–20. DOI: 10.1007/978-3-662-45915-7_2.
- Haselberger, Jana (2023): Weiterbildungsangebote für KI in der Produktion: aktueller Stand und zukünftige Ausrichtung. Masterthesis. Technische Universität Darmstadt, Darmstadt. Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen.
- Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome H. (2017): The elements of statistical learning. Data mining, inference, and prediction. 2. Aufl. New York: Springer (Springer Series in Statistics).
- He, Xin; Zhao, Kaiyong; Chu, Xiaowen (2021): AutoML: A survey of the state-of-the-art. In: *Knowledge-Based Systems* 212, S. 106622. DOI: 10.1016/j.knosys.2020.106622.
- Hegner, Marcus (2003): Methoden zur Evaluation von Software. In: *IZ-Arbeitsbericht* 29, S. 98.
- Heinze, Rolf G.; Kreimeier, Dieter; Wannöffel, Manfred (Hg.) (2021): Lernfabriken an Hochschulen: Neue Lernorte auf dem Vormarsch? Bestandsaufnahme - curriculare Ausrichtungen - Transferkanäle. Düsseldorf: Hans-Böckler-Stiftung (Study / Hans-Böckler-Stiftung, 456).
- Herrmann, Frank (2018): Datenorganisation und Datenbanken. Praxisorientierte Übungen mit MS Access 2016. Wiesbaden: Springer Vieweg (SpringerLink Bücher).
- Heyse, Volker; Erpenbeck, John (2010): Kompetenztraining. Informations- und Trainingsprogramme. 2. Aufl. Stuttgart: Schäffer-Poeschel.
- Hinrichsen, Sven; Riediger, Daniel; Unrau, Alexander (2016): Assistance Systems in Manual Assembly. In: *Production Engineering and Management* (1), S. 3–14.
- Hodaie, Zardosht; Haladjian, Juan; Bruegge, Bernd (2018): TUMA: Towards an Intelligent Tutoring System for Manual-Procedural Activities. In: Roger Nkambou, Roger Azevedo und Julita Vassileva (Hg.): Intelligent tutoring systems. Proceedings of the 14th International Conference, Bd. 10858. Cham: Springer (Lecture Notes in Computer Science, 10858), S. 326–331. DOI: 10.1007/978-3-319-91464-0_35.

- Hoerner, Lorenz; Schamberger, Markus; Bodendorf, Freimut (2023): Using Tacit Expert Knowledge to Support Shop-floor Operators Through a Knowledge-based Assistance System. In: *Computer Supported Cooperative Work* 32 (1), S. 55–91. DOI: 10.1007/s10606-022-09445-4.
- Holzmüller, Hartmut H.; Bandow, Gerhard (2010): Einleitung. Zur disziplinbedingten „Färbung“ von Modellen in der Betriebswirtschaftslehre und den Ingenieurwissenschaften. In: Gerhard Bandow und Hartmut H. Holzmüller (Hg.): "Das ist gar kein Modell". Unterschiedliche Modelle und Modellierungen in Betriebswirtschaftslehre und Ingenieurwissenschaften. 1. Aufl. Wiesbaden: Gabler, S. VII–XIV.
- Horvat, Djerdj; Som, Oliver (2018): Wettbewerbsvorteile durch informationsbasierten Wissensvorsprung. In: Rainer Maria Wagner (Hg.): Industrie 4.0 für die Praxis. Mit realen Fallbeispielen aus mittelständischen Unternehmen und vielen umsetzbaren Tipps. Wiesbaden: Springer Gabler, S. 185–200. DOI: 10.1007/978-3-658-21118-9_14.
- Hsieh, Sheng-Jen; Hsieh, Patricia Yee (2001): Intelligent Tutoring System Authoring Tool for Manufacturing Engineering Education. In: *International Journal of Engineering Education* 17 (6), S. 569–579.
- Huang, Gaoping; Qian, Xun; Wang, Tianyi; Patel, Fagun; Sreeram, Maitreya; Cao, Yuanzhi et al. (2021): AdapTutAR: An Adaptive Tutoring System for Machine Tasks in Augmented Reality. In: Yoshifumi Kitamura (Hg.): Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems. Yokohama. ACM Special Interest Group on Computer-Human Interaction. New York: Association for Computing Machinery (ACM Digital Library), S. 1–15. DOI: 10.1145/3411764.3445283.
- Huber, Steffen; Wiemer, Hajo; Schneider, Dorothea; Ihlenfeldt, Steffen (2018): DMME: Data mining methodology for engineering applications. A holistic extension to the CRISP-DM model. In: *Procedia CIRP* 79, S. 403–408. DOI: 10.1016/j.procir.2019.02.106.
- Hulla, Maria; Herstätter, Patrick; Wolf, Matthias; Ramsauer, Christian (2021): Towards digitalization in production in SMEs – A qualitative study of challenges, competencies and requirements for trainings. In: *Procedia CIRP* 104, S. 887–892. DOI: 10.1016/j.procir.2021.11.149.
- International Organization for Standardization (2023): ISO/IEC 25010: Systems and software engineering, Systems and software Quality Requirements and Evaluation, Berlin, Offenbach: VDE Verlag.
- James, Gareth; Witten, Daniela; Hastie, Trevor; Tibshirani, Robert (2013): An introduction to statistical learning. With applications in R. New York, Heidelberg, Dordrecht, London: Springer (Springer texts in statistics, 103).
- Jardine, Andrew K.S.; Lin, Daming; Banjevic, Dragan (2006): A review on machinery diagnostics and prognostics implementing condition-based maintenance. In: *Mechanical*

Systems and Signal Processing 20 (7), S. 1483–1510. DOI: 10.1016/j.ymssp.2005.09.012.

Jokovic, Benjamin; Nischwitz, Dominik; Hertle, Christian; König, Christina (2017): Entwicklung und Implementierung von arbeitsintegrierten Kompetenzentwicklungsmaßnahmen in produzierenden Unternehmen. In: Gesellschaft für Arbeitswissenschaft e.V. (Hg.): Sozientechnische Gestaltung des digitalen Wandels - kreativ, innovativ, sinnhaft, Beitrag E.1.7. 63. Kongress der Gesellschaft für Arbeitswissenschaft. Brugg-Windisch.

Joshi, Ameet V. (2020): Machine Learning and Artificial Intelligence. 1. Aufl. Cham: Springer (Springer eBook Collection).

Jung, Eberhard (2010): Kompetenzerwerb. Grundlagen, Didaktik, Überprüfbarkeit. Berlin, München, Boston: Walter de Gruyter GmbH.

Kaiser, Jan; Terrazas, German; McFarlane, Duncan; Silva, Lavindra de (2021): Towards low-cost machine learning solutions for manufacturing SMEs. In: *AI & SOCIETY*. DOI: 10.1007/s00146-021-01332-8.

Kano, Noriaki; Seraku, Nobuhiko; Takahashi, Fumio; Tsuji, Shin-ichi (1984): Attractive Quality and Must-Be Quality. In: *Journal of The Japanese Society for Quality Control* 14 (2), S. 147–156.

Kauffeld, Simone; Grote, Sven (2002): Kompetenz - ein strategischer Wettbewerbsfaktor. In: *Personal: Zeitschrift für Human Resource Management* 54 (11), S. 30–32.

Kauffeld, Simone; Truschkat, Inga; Knackstedt, Ralf (2018): Vorwort der Reihenherausgeber/-innen. In: Daniela Ahrens und Gabriele Molzberger (Hg.): Kompetenzentwicklung in analogen und digitalisierten Arbeitswelten. Gestaltung sozialer, organisationaler und technologischer Innovationen. Berlin, Heidelberg: Springer (Kompetenzmanagement in Organisationen), S. V.

Keller, Thimo; Bayer, Christian; Bausch, Phillip; Metternich, Joachim (2019): Benefit evaluation of digital assistance systems for assembly workstations. In: *Procedia CIRP* 81, S. 441–446. DOI: 10.1016/j.procir.2019.03.076.

Kirkpatrick, Donald L.; Kirkpatrick, James D. (2010): Evaluating training programs. The four levels. 3. Aufl. San Francisco: Berrett-Koehler.

Klotzbach, Christoph (2007): Gestaltungsmodell für den industriellen Werkzeugbau. Dissertation. Rheinisch-Westfälische Technische Hochschule Aachen, Aachen.

Kosfeld, Reinhold; Eckey, Hans Friedrich; Türck, Matthias (2016a): Lagemaße. In: Reinhold Kosfeld, Hans Friedrich Eckey und Matthias Türck (Hg.): Deskriptive Statistik. Grundlagen - Methoden - Beispiele - Aufgaben. 6. Aufl. Wiesbaden: Springer Gabler (Lehrbuch), S. 67–108. DOI: 10.1007/978-3-658-13640-6_4.

- Kosfeld, Reinhold; Eckey, Hans Friedrich; Türck, Matthias (2016b): Streuung und Schiefe. In: Reinhold Kosfeld, Hans Friedrich Eckey und Matthias Türck (Hg.): Deskriptive Statistik. Grundlagen - Methoden - Beispiele - Aufgaben. 6. Aufl. Wiesbaden: Springer Gabler (Lehrbuch), S. 109–143. DOI: 10.1007/978-3-658-13640-6_5.
- Kosfeld, Reinhold; Eckey, Hans Friedrich; Türck, Matthias (2016c): Univariate Häufigkeitsverteilungen. In: Reinhold Kosfeld, Hans Friedrich Eckey und Matthias Türck (Hg.): Deskriptive Statistik. Grundlagen - Methoden - Beispiele - Aufgaben. 6. Aufl. Wiesbaden: Springer Gabler (Lehrbuch), S. 37–65. DOI: 10.1007/978-3-658-13640-6_3.
- Kosfeld, Reinhold; Eckey, Hans Friedrich; Türck, Matthias (2016d): Zeitreihenanalyse. In: Reinhold Kosfeld, Hans Friedrich Eckey und Matthias Türck (Hg.): Deskriptive Statistik. Grundlagen - Methoden - Beispiele - Aufgaben. 6. Aufl. Wiesbaden: Springer Gabler (Lehrbuch), S. 281–319. DOI: 10.1007/978-3-658-13640-6_11.
- Krcmar, Helmut; Schwarzer, Bettina (1994): Prozeßorientierte Unternehmensmodellierung. Gründe, Anforderungen an Werkzeuge und Folgen für die Organisation. In: August-Wilhelm Scheer (Hg.): Prozeßorientierte Unternehmensmodellierung. Wiesbaden: Springer Gabler (Schriften zur Unternehmensführung, 53), S. 13–34.
- Kreutzer, Ralf T. (2023): Künstliche Intelligenz Verstehen. Grundlagen - Use-Cases - Unternehmenseigene KI-Journey. 2. Aufl. Wiesbaden: Springer Fachmedien.
- Krüger, Jörg; Vick, Axel; Chemnitz, Moritz; Rosenstrauch, Martin; Hügler, Johannes; Fechteler, Maximilian; Blankenburg, Matthias (2017): Daten, Information und Wissen in Industrie 4.0. In: Gunther Reinhart (Hg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Hanser, S. 89–110. DOI: 10.3139/9783446449893.004.
- Kubik, Christian; Molitor, Dirk Alexander; Becker, Marco; Groche, Peter (2022): Knowledge Discovery in Engineering Applications Using Machine Learning Techniques. In: *Journal of Manufacturing Science and Engineering* 144 (9), Artikel 091003. DOI: 10.1115/1.4054158.
- Kudraß, Thomas (Hg.) (2015): Taschenbuch Datenbanken. 2. Aufl. München: Hanser.
- La Hoz Domínguez, Enrique José de; Fontalvo Herrera, Tomás José; Mendoza Mendoza, Adel Alfonso (2020): Machine Learning and SMEs. Opportunities for an improved decision-making process. In: *Investigación e Innovación en Ingenierías*, S. 21–36. DOI: 10.17081/invinno.8.1.3506.
- Łapińska, Justyna; Escher, Iwona; Górka, Joanna; Sudolska, Agata; Brzustewicz, Paweł (2021): Employees' Trust in Artificial Intelligence in Companies: The Case of Energy and Chemical Industries in Poland. In: *Energies* 14 (1942). DOI: 10.3390/en14071942.
- Lave, Jean; Wenger, Etienne (1991): Situated learning. Legitimate peripheral participation. Cambridge: Cambridge University Press (Learning in doing).

- Lee, Jay; Ni, Jun; Djurdjanovic, Dragan; Qiu, Hai; Liao, Haitao (2006): Intelligent prognostics tools and e-maintenance. In: *Computers in Industry* 57 (6), S. 476–489. DOI: 10.1016/j.compind.2006.02.014.
- Lee, Keon Myung; Yoo, Jaesoo; Kim, Sung Wook; Lee, Jee-Hyong; Hong, Jiman (2019): Autonomic machine learning platform. In: *International Journal of Information Management* 49, S. 491–501. DOI: 10.1016/j.ijinfomgt.2019.07.003.
- Lehner, Franz; Wildner, Stephan; Scholz, Michael (2008): Wirtschaftsinformatik. Eine Einführung. 2. Aufl. München: Hanser.
- Leidinger, Bernhard (2017): Strategie. In: Bernhard Leidinger (Hg.): Wertorientierte Instandhaltung. Kosten senken, Verfügbarkeit erhalten. 2. Aufl. Wiesbaden, Heidelberg: Springer Gabler, S. 15–43. DOI: 10.1007/978-3-658-17855-0_2.
- Li, Jie; Mocko, Megan (2020): Machine learning for a citizen data scientist: an experience with JMP. In: *Journal of Marketing Analytics* 8 (4), S. 267–279. DOI: 10.1057/s41270-020-00092-6.
- Lidwell, William (2010): Universal principles of design. 125 ways to enhance usability, influence perception, increase appeal, make better design decisions, and teach through design. Unter Mitarbeit von Kritina Holden, Jill Butler und Kimberly Elam. 2. Aufl. Beverly: Rockport Publishers.
- Lindemann, Udo (2009): Methodische Entwicklung technischer Produkte. Methoden flexibel und situationsgerecht anwenden. 3. Aufl. Berlin, Heidelberg: Springer (VDI-Buch).
- Little, John Dutton Conant (1970): Models and Managers: The concept of a decision calculus. In: *Management Science* 16 (8), S. 466–485.
- Liu, Chao; Vengayil, Hrishikesh; Zhong, Ray; Xu, Xun (2018): A systematic development method for cyber-physical machine tools. In: *Journal of Manufacturing Systems* 48, S. 13–24. DOI: 10.1016/j.jmsy.2018.02.001.
- Lusti, Markus (2003): Dateien und Datenbanken. Eine anwendungsorientierte Einführung. 4. Aufl. Berlin, Heidelberg: Springer (Springer-Lehrbuch).
- Maćkiewicz, Andrzej; Ratajczak, Waldemar (1993): Principal components analysis (PCA). In: *Computers & Geosciences* 19 (3), S. 303–342. DOI: 10.1016/0098-3004(93)90090-R.
- Mahnke, Wolfgang; Leitner, Stefan-Helmut; Damm, Matthias (2009): OPC Unified Architecture. Berlin, Heidelberg: Springer.
- Mancini, Roberta; Dix, Alan; Levialdi, Stefano (2001): Reflections on Undo. Hg. v. Universität Rom. Online verfügbar unter https://www.researchgate.net/publication/2573267_Reflections_on_Undo, zuletzt geprüft am 28.01.2025.

Manettas, Christos; Bampoula, Xanthi; Nikolakis, Nikolaos; Alexopoulos, Kosmas (2023): A Hybrid Teaching Factory and Asynchronous Learning Method for Improving the Digital Skills of Manufacturing Workforce: The Predictive Maintenance Case. In: *SSRN Journal*. DOI: 10.2139/ssrn.4470492.

Mariscal, Gonzalo; Marbán, Óscar; Fernández, Covadonga (2010): A survey of data mining and knowledge discovery process models and methodologies. In: *The Knowledge Engineering Review* 25 (2), S. 137–166. DOI: 10.1017/S0269888910000032.

Mark, Benedikt G.; Rauch, Erwin; Matt, Dominik T. (2021): Industrial Assistance Systems to Enhance Human–Machine Interaction and Operator’s Capabilities in Assembly. In: Dominik T. Matt, Vladimír Modrák und Helmut Zsifkovits (Hg.): *Implementing Industry 4.0 in SMEs. Concepts, Examples and Applications*. Cham: Palgrave Macmillan, S. 129–161. DOI: 10.1007/978-3-030-70516-9_4.

Martinez-Plumed, Fernando; Contreras-Ochando, Lidia; Ferri, Cesar; Hernandez-Orallo, Jose; Kull, Meelis; Lachiche, Nicolas et al. (2021): CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. In: *IEEE Transactions on Knowledge and Data Engineering* 33 (8), S. 3048–3061. DOI: 10.1109/TKDE.2019.2962680.

Mayr, Andreas; Kißkalt, Dominik; Meiners, Moritz; Lutz, Benjamin; Schäfer, Franziska; Seidel, Reinhardt et al. (2019): Machine Learning in Production – Potentials, Challenges and Exemplary Applications. In: *Procedia CIRP* 86, S. 49–54. DOI: 10.1016/j.procir.2020.01.035.

Mazzei, Daniele; Ramjattan, Reshawn (2022): Machine Learning for Industry 4.0: A Systematic Review Using Deep Learning-Based Topic Modelling. In: *Sensors* (22). DOI: 10.3390/s22228641.

McCarthy, John; Minsky, Marvin L.; Rochester, Nathaniel; Shannon, Claude E. (2006): A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. In: *AI Magazine* 27 (4), S. 12. DOI: 10.1609/aimag.v27i4.1904.

Mehler, Lisa; Terhoeven, Jan; Wischniewski, Sascha (2021): Lernförderliche Arbeitsgestaltung und kontextsensitive Assistenzsysteme. In: Peter Dehnbostel, Götz Richter, Thomas Schröder und Anita Tisch (Hg.): *Kompetenzentwicklung in der digitalen Arbeitswelt. Zukünftige Anforderungen und berufliche Lernchancen*. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 109–124.

Meise, Volker (2001): *Ordnungsrahmen zur prozessorientierten Organisationsgestaltung. Modelle für das Management komplexer Reorganisationsprojekte*. Dissertation. Universität Hamburg, Hamburg.

Merkel, Lukas; Berger, Christoph; Braunreuther, Stefan; Reinhart, Gunther (2018): Determination of Cognitive Assistance Functions for Manual Assembly Systems. In: Tareq Z. Ahram (Hg.): *Advances in human factors in wearable technologies and game design*.

AHFE 2018. Cham: Springer (Advances in Intelligent Systems and Computing, 795), S. 198–207. DOI: 10.1007/978-3-319-94619-1_19.

Merkelbach, Silke; Enzberg, Sebastian von; Kuhn, Arno; Dumitrescu, Roman (2022): Towards a Process Model to Enable Domain Experts to Become Citizen Data Scientists for Industrial Applications. In: Proceedings of the 5th IEEE International Conference on Industrial Cyber-Physical System. Coventry. Institute of Electrical and Electronics Engineers. Piscataway, New Jersey, S. 1–6. DOI: 10.1109/ICPS51978.2022.9816871.

Metternich, Joachim; Biegel, Tobias; Bretones Cassoli, Beatriz; Hoffmann, Felix; Jourdan, Nicolas; Rosemeyer, Jannik et al. (2021): Künstliche Intelligenz zur Umsetzung von Industrie 4.0 im Mittelstand. Expertise des Forschungsbeirats der Plattform Industrie 4.0. Hg. v. Forschungsbeirat der Plattform Industrie 4.0 und acatech - Deutsche Akademie der Technikwissenschaften. München.

Metternich, Joachim; Hertle, Christian; Tisch, Michael; Jokovic, Benjamin; König, Christina; Bruder, Ralph et al. (2018): Betriebliche Kompetenzentwicklungsansätze zur Weiterentwicklung fachlich-methodischer und sozial-kommunikativer Kompetenzen in produktionsnahen Bereichen. In: Daniela Ahrens und Gabriele Molzberger (Hg.): Kompetenzentwicklung in analogen und digitalisierten Arbeitswelten. Gestaltung sozialer, organisationaler und technologischer Innovationen. Berlin, Heidelberg: Springer (Kompetenzmanagement in Organisationen), S. 73–87. DOI: 10.1007/978-3-662-54956-8_6.

Mhlanga, David (2023): Artificial Intelligence and Machine Learning for Energy Consumption and Production in Emerging Markets: A Review. In: *Energies* 16 (2), S. 745. DOI: 10.3390/en16020745.

Mielke, P. W.; Berry, K. J. (2009): A note on Cohen's weighted kappa coefficient of agreement with linear weights. In: *Statistical Methodology* 6 (5), S. 439–446. DOI: 10.1016/j.stamet.2009.03.002.

Mir, Shabir Ahmad; Quadri, S. M. K. (2009): Decision Support Systems: Concepts, Progress and Issues – A Review. In: Eric Lichtfouse (Hg.): Climate change, intercropping, pest control and beneficial microorganisms. Dordrecht, Heidelberg: Springer (Sustainable agriculture reviews, 2), S. 373–399. DOI: 10.1007/978-90-481-2716-0_13.

Mitchell, Tom M. (1997): Machine learning. New York, USA: McGraw-Hill (McGraw-Hill series in computer science).

Mockenhaupt, Andreas (2021): Digitalisierung und Künstliche Intelligenz in der Produktion. Grundlagen und Anwendung. Unter Mitarbeit von Jürgen Rüttgers. Wiesbaden, Heidelberg: Springer Vieweg (Lehrbuch).

Modbus Organization (2006): MODBUS over Serial Line. Specification and Implementation Guide. V1.02. Andover, USA. Online verfügbar unter https://modbus.org/docs/Modbus_over_serial_line_V1_02.pdf, zuletzt geprüft am 26.02.2025.

Molano, José Ignacio Rodríguez; Lovelle, Juan Manuel Cueva; Montenegro, Carlos Enrique; Granados, J. Javier Rainer; Crespo, Rubén González (2018): Metamodel for integration of Internet of Things, Social Networks, the Cloud and Industry 4.0. In: *Journal of Ambient Intelligence and Humanized Computing* 9 (3), S. 709–723. DOI: 10.1007/s12652-017-0469-5.

Montero, Jose D. (2008): Introduction to Data Mining and its Applications to Manufacturing. In: John Wang (Hg.): Data warehousing and mining. Concepts, methodologies, tools, and applications. Hershey, USA: Information Science Reference, S. 146–168. DOI: 10.4018/978-1-59904-951-9.ch012.

Moody, Daniel L.; Shanks, Graeme G. (1994): What makes a good data model? Evaluating the quality of entity relationship models. In: Pericles Loucopoulos (Hg.): Entity-relationship approach. 13th International Conference on the Entity-Relationship Approach. Berlin, Heidelberg: Springer (Lecture Notes in Computer Science, 881), S. 94–111. DOI: 10.1007/3-540-58786-1_75.

Mozilla Foundation (2025): Working with JSON. Online verfügbar unter https://developer.mozilla.org/en-US/docs/Learn_web_development/Core/Scripting/JSON#see_also, zuletzt geprüft am 24.02.2025.

MQTT.org (2025): MQTT Specifications. Online verfügbar unter <https://mqtt.org/mqtt-specification/>, zuletzt geprüft am 26.02.2025.

MTConnect Institute (2025): Documentation. Hg. v. Association For Manufacturing Technology. Online verfügbar unter <https://www.mtconnect.org/documentation>, zuletzt geprüft am 26.02.2025.

Mullarkey, Matthew T.; Hevner, Alan R.; Grandon Gill, T.; Dutta, Kaushik (2019): Citizen Data Scientist: A Design Science Research Method for the Conduct of Data Science Projects. In: Bengisu Tulu, Soussan Djamassbi und GONDY Leroy (Hg.): Extending the boundaries of design science theory and practice. 14th International Conference on Design Science Research in Information Systems and Technology. Cham: Springer (Lecture Notes in Computer Science, 11491), S. 191–205. DOI: 10.1007/978-3-030-19504-5_13.

Murphy, Kevin P. (2014): Machine Learning. A Probabilistic Perspective. Cambridge: MIT Press (Adaptive computation and machine learning).

Mypati, Omkar; Mukherjee, Avishek; Mishra, Debasish; Pal, Surjya Kanta; Chakrabarti, Partha Pratim; Pal, Arpan (2023): A critical review on applications of artificial intelligence in manufacturing. In: *Artificial Intelligence Review* 56 (S1), S. 661–768. DOI: 10.1007/s10462-023-10535-y.

Nelles, Jochen; Kuz, Sinem; Mertens, Alexander; Schlick, Christopher M. (2016): Human-centered design of assistance systems for production planning and control: The role of the human in Industry 4.0. In: Proceedings of the 2016 IEEE International Conference on Industrial Technology. Taipei. Institute of Electrical and Electronics

Engineers; IEEE Industrial Electronics Society. Piscataway, New Jersey, S. 2099–2104. DOI: 10.1109/ICIT.2016.7475093.

Neunzig, Christian; Möllensiep, Dennis; Hartmann, Melanie; Kuhlenkötter, Bernd; Möller, Matthias; Schulz, Jürgen (2023a): Enhanced classification of hydraulic testing of directional control valves with synthetic data generation. In: *Production Engineering* 17 (5), S. 669–678. DOI: 10.1007/s11740-023-01204-8.

Neunzig, Christian; Möllensiep, Dennis; Kuhlenkötter, Bernd; Möller, Matthias (2023b): ML Pro: digital assistance system for interactive machine learning in production. In: *Journal of Intelligent Manufacturing* 35, S. 3479–3499. DOI: 10.1007/s10845-023-02214-0.

Ng, Thomas W. H.; Feldman, Daniel C. (2012): Evaluating Six Common Stereotypes About Older Workers with Meta-Analytical Data. In: *Personnel Psychology* 65 (4), S. 821–858. DOI: 10.1111/peps.12003.

Nielsen, Jakob (2010): Usability engineering. 3. Aufl. Amsterdam, Heidelberg: Kaufmann.

Nixdorf, Steffen; Ansari, Fazel; Schlund, Sebastian; Wolf, Matthias; Hulla, Maria; Papa, Maximilian et al.: Work-Based Learning in Manufacturing Industry. A Sector-Based Meta-Analysis. Wien. Online verfügbar unter <https://researchdata.tuwien.at/records/ed096-ac543>, zuletzt geprüft am 28.01.2025.

Nkambou, Roger; Bourdeau, Jacqueline; Psyché, Valéry (2010): Building Intelligent Tutoring Systems: An Overview. In: Roger Nkambou, Jacqueline Bourdeau und Riichiro Mizoguchi (Hg.): *Advances in intelligent tutoring systems*. Berlin, Heidelberg: Springer (Studies in Computational Intelligence, 308), S. 361–375. DOI: 10.1007/978-3-642-14363-2_18.

North, Klaus (2016): Wissensorientierte Unternehmensführung. Wissensmanagement gestalten. 6. Aufl. Wiesbaden: Springer Gabler (Lehrbuch).

Nti, Isaac Kofi; Adekoya, Adebayo Felix; Weyori, Benjamin Asubam; Nyarko-Boateng, Owusu (2022): Applications of artificial intelligence in engineering and manufacturing: a systematic review. In: *Journal of Intelligent Manufacturing* 33 (6), S. 1581–1601. DOI: 10.1007/s10845-021-01771-6.

OpenAI (2025): ChatGPT. Online verfügbar unter <https://openai.com/index/chatgpt/>.

Pacaux-Lemoine, Marie-Pierre; Trentesaux, Damien; Zambrano Rey, Gabriel; Millot, Patrick (2017): Designing intelligent manufacturing systems through Human-Machine Cooperation principles: A human-centered approach. In: *Computers & Industrial Engineering* 111, S. 581–595. DOI: 10.1016/j.cie.2017.05.014.

Papenberg, Björn; Hogreve, Sebastian; Tracht, Kirsten (2022): Experimental spaces for the introduction of disruptive technologies in production. In: 11th International Conference on Through-life Engineering Services. TESConf. Cranfield, S. 4264.

- Patzak, Gerold (1982): Systemtechnik - Planung komplexer innovativer Systeme. Grundlagen, Methoden, Techniken. Berlin: Springer.
- Pavlič, Sašo; Fister Jr., Iztok; Karakatič, Sašo (2022): NiaNet: A framework for constructing Autoencoder architectures using nature-inspired algorithms. In: Proceedings of the 17th Conference on Computer Science and Intelligence Systems. Sofia. Piscataway, New Jersey: IEEE (Annals of Computer Science and Information Systems), S. 109–116. DOI: 10.15439/2022F192.
- Peifer, Yannick; Jeske, Tim; Hille, Sven (2022): Artificial Intelligence and its Impact on Leaders and Leadership. In: *Procedia Computer Science* 200, S. 1024–1030. DOI: 10.1016/j.procs.2022.01.301.
- Pham, D. T.; Afifi, Afef Afifi (2005): Machine-learning techniques and their applications in manufacturing. In: *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 219 (5), S. 395–412. DOI: 10.1243/095440505X32274.
- Phan, Thuy Linh Jenny; Gehrhardt, Ingolf; Heik, David; Bahrpeyma, Fouad; Reichelt, Dirk (2022): A Systematic Mapping Study on Machine Learning Techniques Applied for Condition Monitoring and Predictive Maintenance in the Manufacturing Sector. In: *Logistics* 6 (2), S. 35. DOI: 10.3390/logistics6020035.
- Piorkowski, David; Park, Soya; Wang, April Yi; Wang, Dakuo; Muller, Michael; Portnoy, Felix (2021): How AI Developers Overcome Communication Challenges in a Multidisciplinary Team. In: *Proceedings of the ACM on Human-Computer Interaction* 5, S. 1–25. DOI: 10.1145/3449205.
- Pitsch, Martin (2014): Kompetenzfeldbasierte Vernetzung von Werkzeugbaustandorten. Dissertation. Fraunhofer-Institut für Produktionstechnologie IPT, Aachen.
- Planing, Patrick (2022): Statistik Grundlagen. Das neue Lehrbuch mit über 200 YouTube-Videos rund um die Burgerkette FIVE PROFS. Unter Mitarbeit von Ilena Becic. Stuttgart: Planing Publishing.
- Preim, Bernhard (2010): Interaktive Systeme. Band 1: Grundlagen, Graphical User Interfaces, Informationsvisualisierung. Unter Mitarbeit von Raimund Dachzelt. 2. Aufl. Berlin, Heidelberg: Springer (eXamen.press).
- Pressman, Roger S.; Maxim, Bruce R. (2015): Software engineering. A practitioner's approach. 8. Aufl. New York: McGraw-Hill Education (McGraw-Hill higher education).
- Preusche, Christian (2018): Clusterbasierte Zustandsbewertung von technischen Systemen zur Unterstützung der prädiktiven Instandhaltung. Dissertation. Technische Universität Darmstadt, Darmstadt.

PROFIBUS Nutzerorganisation (2025a): Profibus. Hg. v. PROFIBUS & PROFINET International. Karlsruhe. Online verfügbar unter <https://www.profibus.de/profibusb#ber-sicht>, zuletzt geprüft am 26.02.2025.

PROFIBUS Nutzerorganisation (2025b): Profinet. Hg. v. PROFIBUS & PROFINET International. Karlsruhe. Online verfügbar unter <https://www.profibus.de/profinet>, zuletzt geprüft am 26.02.2025.

Rammer, Christian (2022): Kompetenzen und Kooperationen zu Künstlicher Intelligenz. Ergebnisse einer Befragung von KI-aktiven Unternehmen in Deutschland. Unter Mitarbeit von Christian Rammer. Hg. v. Bundesministerium für Wirtschaft und Klimaschutz (BMWK). Berlin. Online verfügbar unter https://www.de.digital/DIGITAL/Redaktion/DE/Digitalisierungsindex/Publikationen/publikation-download-ki-kompetenzen.pdf?__blob=publicationFile&v=4, zuletzt geprüft am 28.01.2025.

Rat der Europäischen Union (2017): Council Recommendation of 22 May 2017 on the European Qualifications Framework for lifelong learning and repealing the recommendation of the European Parliament and of the Council of 23 April 2008 on the establishment of the European Qualifications Framework for lifelong learning. Brüssel (2017/C 189/03). Online verfügbar unter [https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017H0615\(01\)&from=EN](https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017H0615(01)&from=EN), zuletzt geprüft am 28.01.2025.

Rauch, Erwin; Linder, Christian; Dallasega, Patrick (2020): Anthropocentric perspective of production before and within Industry 4.0. In: *Computers & Industrial Engineering* 139, S. 105644. DOI: 10.1016/j.cie.2019.01.018.

Renkl, Alexander (1994): Träges Wissen. Die "unerklärliche" Kluft zwischen Wissen und Handeln. Forschungsbericht Nr. 41. München.

Ribbat, Mirko (2020): Führungskräfte als Gatekeeper für arbeitsintegriertes Lernen. Mit Learning Contracts die Gestaltung des digitalen Wandels ermöglichen. In: Götz Richter (Hg.): Lernen in der digitalen Transformation. Wie arbeitsintegriertes Lernen in der betrieblichen Praxis gelingt. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 83–94.

Ribeiro, Marco Tulio; Singh, Sameer; Guestrin, Carlos (2016): "Why Should I Trust You?". In: Balaji Krishnapuram (Hg.): Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco. Association for Computing Machinery; ACM Special Interest Group on Management of Data; ACM Special Interest Group on Knowledge Discovery in Data. New York, S. 1135–1144. DOI: 10.1145/2939672.2939778.

Rich, Elaine (1987): Artificial intelligence. 6. Aufl. New York: McGraw-Hill (McGraw-Hill series in artificial intelligence).

Richter, Götz; Mühlenbrock, Inga (2020): Kompetenzentwicklung und Arbeitsfähigkeit im digitalen Wandel. In: Götz Richter (Hg.): Lernen in der digitalen Transformation.

Wie arbeitsintegriertes Lernen in der betrieblichen Praxis gelingt. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 95–109.

Richter, Götz; Ribbat, Mirko; Mühlenbrock, Inga; Wendsche, Johannes (2018): Perspektiven des arbeitsintegrierten Lernens in Forschung und Praxis. In: *Arbeit* 27 (4), S. 401–404. DOI: 10.1515/arbeit-2018-0028.

Rodrigues, Manuel; Novais, Paulo; Santos, Manuel Filipe (2005): Future challenges in intelligent tutoring systems - A framework. In: A. Méndez-Villas, B. Gonzalez Pereira, J. Mesa González und J. A. Mesa González (Hg.): *Recent Research Developments in Learning Technologies. International Conference on Multimedia and Information & Communication Technologies in Education*. Cáceres: Formatex, S. 929–934.

Rokoss, Alexander; Kramer, Katharina; Schmidt, Matthias (2021): A learning factory approach on machine learning in production companies. How a learning factory approach can help to increase the understanding of the application of machine learning tasks on production planning and control tasks. In: Wilfried Sihm und Sebastian Schlund (Hg.): *Competence development and learning assistance systems for the data-driven future*. Berlin: GITO Verlag (Schriftenreihe der Wissenschaftlichen Gesellschaft für Arbeits- und Betriebsorganisation e.V.), S. 125–142. DOI: 10.30844/wgab_2021_8.

Romero, David; Bernus, Peter; Noran, Ovidiu; Stahre, Johan; Fast-Berglund, Åsa (2016): The Operator 4.0: Human Cyber-Physical Systems & Adaptive Automation Towards Human-Automation Symbiosis Work Systems. In: Irenilza A. Nääs, Oduvaldo Vendrametto, João Mendes Reis, Rodrigo Franco Gonçalves, Márcia Terra Silva, Gregor von Cieminski und Dimitris Kiritsis (Hg.): *Advances in Production Management Systems. Initiatives for a sustainable world*. Cham: Springer (488), S. 677–686. DOI: 10.1007/978-3-319-51133-7_80.

Rosemann, Michael; Schwegmann, Ansgar; Delfmann, Patrick (2012): Vorbereitung der Prozessmodellierung. In: Jörg Becker, Martin Kugeler und Michael Rosemann (Hg.): *Prozessmanagement. Ein Leitfaden zur prozessorientierten Organisationsgestaltung*. Berlin, Heidelberg: Springer Gabler, S. 47–111.

Rosemeyer, Jannik (2025a): Auswertung der Anwendung des TAS in der Praxis. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4619>, zuletzt geprüft am 30.05.2025.

Rosemeyer, Jannik (2025b): Ergebnisse der Evaluationsumfragen. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4620>, zuletzt geprüft am 30.05.2025.

Rosemeyer, Jannik (2025c): Ergebnisse der Kano-Analyse. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4623>, zuletzt geprüft am 30.05.2025.

Rosemeyer, Jannik (2025d): Prompts zur Strukturierungsunterstützung der Anhänge. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4679>, zuletzt geprüft am 18.07.2025.

Rosemeyer, Jannik; Bardy, Sebastian; Pinzone, Marta; Bosani, Enrica; Schubert, Tobias; Metternich, Joachim (2022): Towards artificial intelligence in production: A competence profile for shop floor managers. In: *SSRN Journal*. DOI: 10.2139/ssrn.4072671.

Rosemeyer, Jannik; Beck, Laurenz; Metternich, Joachim (2023): A Cognitive Assistance System To Support The Implementation Of Machine Learning Applications In Manufacturing. Unter Mitarbeit von Technische Informationsbibliothek (TIB), David Herberger, Marco Hübner und Volker Stich. Hannover: publish-Ing.

Rosemeyer, Jannik; Bretones Cassoli, Beatriz; Jourdan, Nicolas; Biegel, Tobias; Hoffmann, Felix; Ziegenbein, Amina; Metternich, Joachim (2021): Künstliche Intelligenz für KMU. Ein Leitfaden zur Einführung von KI im Produktionsumfeld. In: *Industrie 4.0 und IIoT* (24), S. 9–10.

Rosemeyer, Jannik; Haselberger, Jana (2025): Ergebnisse der Internetrecherche. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4622>, zuletzt geprüft am 30.05.2025.

Rosemeyer, Jannik; Metternich, Joachim (2023): Weiterbildung und Wertschöpfung an einem Ort: Neues betriebliches Lernen für KI-Anwendungen in der Produktion. EMO-Hannover Webnews (Kategorie „Future Business“). Universitäts- und Landesbibliothek Darmstadt; Mondiale de la Machine Outil. Darmstadt. DOI: 10.26083/TUPRINTS-00023273.

Rosemeyer, Jannik; Metternich, Joachim (2024): Human-Centered Design for Digital Machine Learning Assistance Systems in Work-Based Learning. In: Sebastian Thiede und Eric Lutters (Hg.): *Learning Factories of the Future. Proceedings of the 14th Conference on Learning Factories 2024, Volume 1*. 1. Aufl. Cham: Springer Nature Switzerland; Imprint Springer (Lecture Notes in Networks and Systems, 1059), S. 155–162. DOI: 10.1007/978-3-031-65411-4_19.

Rosemeyer, Jannik; Metternich, Joachim (2025): Ergebnisse der Unterstützungsevaluation. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4624>, zuletzt geprüft am 30.05.2025.

Rosemeyer, Jannik; Neunzig, Christian; Akbal, Cem; Metternich, Joachim; Kuhlenkötter, Bernd (2024a): A maturity model for digital ML tools to be used in manufacturing environments. Universitäts- und Landesbibliothek Darmstadt. Darmstadt. DOI: 10.26083/TUPRINTS-00026519.

Rosemeyer, Jannik; Pinzone, Marta; Metternich, Joachim (2024b): Digital Assistance Systems to Implement Machine Learning in Manufacturing: A Systematic Review. In:

Machine Learning and Knowledge Extraction 6 (4), S. 2808–2828. DOI: 10.3390/make6040134.

Rosemeyer, Jannik; Tian, Yilin; Beck, Laurenz; Gallus, Josef; Mao, Jiahe; Ben Sassi, Slim et al. (2025): Softwarearchitektur und Programmcode. Hg. v. Technische Universität Darmstadt. Darmstadt. Online verfügbar unter <https://tudatalib.ulb.tu-darmstadt.de/handle/tudatalib/4621>, zuletzt geprüft am 30.05.2025.

Rudin, Cynthia; Radin, Joanna (2019): Why Are We Using Black Box Models in AI When We Don't Need To? A Lesson From an Explainable AI Competition. In: *Harvard Data Science Review* 1 (2). DOI: 10.1162/99608f92.5a8a3a3d.

Rueckert, Patrick; Papenberg, Björn; Sievers, Torsten Sebastian; Tracht, Kirsten (2021): On-Site Learning Factories for Implementing Artificial Intelligence Systems in Production. In: *SSRN Journal*. DOI: 10.2139/ssrn.3864445.

Russell, Stuart; Norvig, Peter (2016): Artificial intelligence. A modern approach. 3. Aufl. Boston: Pearson.

Salminen, Katri; Hautamäki, Pia; Jähi, Markus (2024): Aligning Industry Needs and Education: Unlocking the Potential of AI via Skills. In: 2024 Portland International Conference on Management of Engineering and Technology. Portland, USA. Institute of Electrical and Electronics Engineers. Piscataway, New Jersey: IEEE, S. 1–10. DOI: 10.23919/PICMET64035.2024.10653328.

Samatas, Gerasimos G.; Moumgiakmas, Seraphim S.; Papakostas, George A. (2021): Predictive Maintenance - Bridging Artificial Intelligence and IoT. In: Rajashree Paul (Hg.): 2021 IEEE World AI IoT Congress. Seattle. Institute of Electrical and Electronics Engineers. Piscataway, New Jersey: IEEE, S. 413–419. DOI: 10.1109/AI-IoT52608.2021.9454173.

Samuel, Arthur L. (1959): Some Studies in Machine Learning Using the Game of Checkers. In: *IBM Journal of Research and Development* 3 (3), S. 210–229. DOI: 10.1147/rd.33.0210.

Sarodnick, Florian; Brau, Henning (2011): Methoden der Usability Evaluation. 2. Aufl.: Verlag Hans Huber.

Sauerwein, Elmar (2000): Das Kano-Modell der Kundenzufriedenheit. In: Elmar Sauerwein (Hg.): Das Kano-Modell der Kundenzufriedenheit. Reliabilität und Validität einer Methode zur Klassifizierung von Produkteigenschaften. Wiesbaden: Deutscher Universitätsverlag; Gabler (Gabler Edition Wissenschaft), S. 27–55. DOI: 10.1007/978-3-322-90890-2_3.

Schiersmann, Christiane (2007): Berufliche Weiterbildung. Wiesbaden: VS Verlag für Sozialwissenschaften (Springer eBook Collection Humanities, Social Science).

Schildt, Herbert (2019): Java. The complete reference. 11. Aufl. New York: McGraw-Hill Education.

Schliephake, Judith; Cordes, Anja (2023): Der Einsatz von künstlicher Intelligenz (KI) in KMU und Handwerk. Ausgangsbedingungen und erforderliche Kompetenzen. Hg. v. Projekt KomKI. Bundesministerium für Arbeit und Soziales. Lübeck.

Schlund, Sebastian (2023): Assistenzsysteme. In: Oliver Riedel, Katharina Hölzle, Sebastian Schlund und Dieter Spath (Hg.): Handbuch Unternehmensorganisation. Strategien, Planung, Umsetzung. Berlin, Heidelberg: Springer Vieweg (Springer Reference Technik), S. 1–16. DOI: 10.1007/978-3-642-45370-0_90-1.

Schmidt, Henk G. (1983): Problem-based learning: rationale and description. In: *Medical education* 17 (1), S. 11–16. DOI: 10.1111/j.1365-2923.1983.tb01086.x.

Schreiber, Markus (2024): Konfiguration von Traceability-Systemen für den Einsatz von Process Mining in der diskreten Fertigung. Dissertation. Shaker Verlag; Technische Universität Darmstadt, Darmstadt.

Schulz, Michael; Neuhaus, Uwe; Kaufmann, Jens; Badura, Daniel; Kerzel, Ulrich; Welter, Felix et al. (2020): DASC-PM v1.0 - Ein Vorgehensmodell für Data-Science-Projekte. Unter Mitarbeit von Universitäts- und Landesbibliothek Sachsen-Anhalt und Martin-Luther Universität. Hamburg, Elmshorn.

Schuster, Christof (2004): A Note on the Interpretation of Weighted Kappa and its Relations to Other Rater Agreement Statistics for Metric Scales. In: *Educational and Psychological Measurement* 64 (2), S. 243–253. DOI: 10.1177/0013164403260197.

Schütte, Reinhard (1998): Grundsätze ordnungsmäßiger Referenzmodellierung. Konstruktion konfigurations- und anpassungsorientierter Modelle. Dissertation. Wiesbaden: Springer Gabler (Neue betriebswirtschaftliche Forschung, 233).

Seifert, Inessa; Bürger, Matthias; Wangler, Leo; Christmann-Budian, Stephanie; Rohde, Marieke; Gabriel, Peter; Zinke, Guido (2018): Potenziale der Künstlichen Intelligenz im produzierenden Gewerbe in Deutschland. Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmen der Begleitforschung zum Technologieprogramm PAiCE – Platforms | Additive Manufacturing | Imaging | Communication | Engineering. Hg. v. Begleitforschung PAiCE und iit-Institut für Innovation und Technik in der VDI / VDE Innovation + Technik GmbH. Berlin.

Senderek, Roman; Geisler, Katrin; Schulz, Michael; Neuhaus, Uwe; Kaufmann, Jens; Badura, Daniel et al. (2015): Assistenzsysteme zur Lernunterstützung in der Industrie 4.0. In: Sabine Rathmayer und Hans Pongratz (Hg.): Proceedings of DeLFI Workshops und 13th e-Learning Conference of the German Computer Society. München, S. 36–46.

Senna, Pedro P.; Almeida, António H.; Barros, Ana C.; Bessa, Ricardo J.; Azevedo, Américo L. (2020): Architecture Model for a Holistic and Interoperable Digital Energy Management Platform. In: *Procedia Manufacturing* 51, S. 1117–1124. DOI: 10.1016/j.promfg.2020.10.157.

Shafranovic, Yakov (2005): Common Format and MIME Type for Comma-Separated Values (CSV) Files. Hg. v. The Internet Society (Request for Comments, 4180). Online verfügbar unter <https://datatracker.ietf.org/doc/html/rfc4180>, zuletzt geprüft am 28.01.2025.

Shahin, Arash; Zairi, Mohamed (2009): Kano model: A dynamic approach for classifying and prioritising requirements of airline travellers with three case studies on international airlines. In: *Total Quality Management & Business Excellence* 20 (9), S. 1003–1028. DOI: 10.1080/14783360903181867.

Shalev-Shwartz, Shai (2014): Understanding Machine Learning. Unter Mitarbeit von Shai Ben-David. 1. Aufl. West Nyack: Cambridge University Press.

Shneiderman, Ben; Plaisant, Catherine (2005): Designing the user interface. Strategies for effective human-computer interaction. 4. Aufl. Boston, München: Pearson/Addison-Wesley.

Sjödín, David R.; Parida, Vinit; Leksell, Markus; Petrovic, Aleksandar (2018): Smart Factory Implementation and Process Innovation. In: *Research-Technology Management* 61 (5), S. 22–31. DOI: 10.1080/08956308.2018.1471277.

Socolofsky, Theodore John; Kale, Claudia Jeanne (1991): A TCP/IP Tutorial. Hg. v. Spider Systems Limited (Request for Comments, 1180). Online verfügbar unter <https://datatracker.ietf.org/doc/html/rfc1180>, zuletzt geprüft am 26.02.2025.

Spillner, Andreas; Linz, Tilo (2019): Basiswissen Softwaretest. Aus- und Weiterbildung zum Certified Tester – Foundation Level nach ISTQB®-Standard. 6. Aufl. Heidelberg: dpunkt.verlag.

Spöttl, Georg; Windelband, Lars (2019): Industrie 4.0. Risiken und Chancen für die Berufsbildung. 2. Aufl. Bielefeld: wbv (Berufsbildung, Arbeit und Innovation, Band 52).

Stachowiak, Herbert (1973): Allgemeine Modelltheorie. Wien, New York: Springer.

Staufen AG (2024): Performance-Treiber 2024. So erreichen Unternehmen Operational Excellence. Hg. v. Staufen AG. Köngen. Online verfügbar unter <https://www.staufen.ag/insights/studien-whitepaper/studie-performance-treiber-2024/#Studie-digi-kontaktformular>, zuletzt geprüft am 28.01.2025.

Stork, Werner; Helferich, Pia Sue; Pleil, Thomas (2020): Beschäftigte in der digitalen Transformation – Möglichkeiten des arbeitsintegrierten informellen Lernens. In: Götz Richter (Hg.): Lernen in der digitalen Transformation. Wie arbeitsintegriertes Lernen in der betrieblichen Praxis gelingt. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 35–50.

Studer, Stefan; Bui, Thanh Binh; Drescher, Christian; Hanuschkin, Alexander; Winkler, Ludwig; Peters, Steven; Mueller, Klaus-Robert (2021): Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology. In: *Machine Learning and Knowledge Extraction* 3 (2), S. 392–413.

Sutharssan, Thamo; Stoyanov, Stoyan; Bailey, Chris; Yin, Chunyan (2015): Prognostic and health management for engineering systems: a review of the data-driven approach and algorithms. In: *The Journal of Engineering* (7), S. 215–222. DOI: 10.1049/joe.2014.0303.

Sutton, Richard S.; Barto, Andrew (2020): Reinforcement learning. An introduction. 2. Aufl. Cambridge, Massachusetts, London: The MIT Press (Adaptive computation and machine learning).

Tenberg, Ralf (2011): Vermittlung fachlicher und überfachlicher Kompetenzen in technischen Berufen. Theorie und Praxis der Technikdidaktik. 1. Aufl. Stuttgart: Franz Steiner Verlag.

Terhoeven, Jan; Mühlenbrock, Inga; Mehler, Lisa; Ribbat, Mirko; Tisch, Anita; Wischniewski, Sascha (2019): Lernförderlichkeit im Kontext einer menschengerechten Arbeitssystemgestaltung. In: Gesellschaft für Arbeitswissenschaft e.V. (Hg.): Arbeit interdisziplinär analysieren – bewerten – gestalten. Dresden. 65. Kongress der Gesellschaft für Arbeitswissenschaft: Institut für Arbeit und Gesundheit der Deutschen Gesetzlichen Unfallversicherung in Kooperation mit dem Institut für Technische Logistik und Arbeitssysteme, C.10.15.

Theng, Dipti; Bhoyar, Kishor K. (2024): Feature selection techniques for machine learning: a survey of more than two decades of research. In: *Knowledge and Information Systems* 66 (3), S. 1575–1637. DOI: 10.1007/s10115-023-02010-5.

Thesmann, Stephan (2016): Interface Design. Usability, User Experience und Accessibility im Web gestalten. 2. Aufl. Wiesbaden: Springer Vieweg.

Tian, Jilun; Jiang, Yuchen; Zhang, Jiusi; Luo, Hao; Yin, Shen (2024): A novel data augmentation approach to fault diagnosis with class-imbalance problem. In: *Reliability Engineering & System Safety* 243, S. 109832. DOI: 10.1016/j.res.2023.109832.

Tiddens, Wieger; Braaksma, Jan; Tinga, Tiedo (2015): The Adoption of Prognostic Technologies in Maintenance Decision Making: A Multiple Case Study. In: *Procedia CIRP* 38, S. 171–176. DOI: 10.1016/j.procir.2015.08.028.

Tiddens, Wieger; Braaksma, Jan; Tinga, Tiedo (2020): Exploring predictive maintenance applications in industry. In: *Journal of Quality in Maintenance Engineering* 28 (1), S. 68–85. DOI: 10.1108/JQME-05-2020-0029.

Tisch, Anita; Richter, Götz; Ribbat, Mirko (2021): Die digitale Transformation der Arbeit. Lernanforderungen und Lernchancen. In: Peter Dehnpostel, Götz Richter, Thomas Schröder und Anita Tisch (Hg.): Kompetenzentwicklung in der digitalen Arbeitswelt. Zukünftige Anforderungen und berufliche Lernchancen. 1. Aufl. Freiburg: Schäffer-Poeschel Verlag für Wirtschaft Steuern Recht GmbH, S. 93–107.

Tisch, Michael (2018): Modellbasierte Methodik zur kompetenzorientierten Gestaltung von Lernfabriken für die schlanke Produktion. Dissertation. Technische Universität Darmstadt, Darmstadt.

Tisch, Michael; Hertle, Christian; Abele, Eberhard; Metternich, Joachim; Tenberg, Ralf (2015): Learning factory design: a competency-oriented approach integrating three design levels. In: *International Journal of Computer Integrated Manufacturing* 29 (12), S. 1355–1375. DOI: 10.1080/0951192X.2015.1033017.

Tisch, Michael; Hertle, Christian; Cachay, Jan; Abele, Eberhard; Metternich, Joachim; Tenberg, Ralf (2013): A Systematic Approach on Developing Action-oriented, Competency-based Learning Factories. In: *Procedia CIRP* 7, S. 580–585. DOI: 10.1016/j.procir.2013.06.036.

Tisch, Michael; Hertle, Christian; Metternich, Joachim; Abele, Eberhard (2014): Lernerfolgsmessung in Lernfabriken. Kompetenzorientierte Weiterentwicklung praxisnaher Schulungen. In: *Industrie Management* 30 (3), S. 20–24.

Töllner, Alke; Jungmann, Thorsten; Bückner, Matthias; Brutschek, Tobias (2010): Modelle und Modellierung. Terminologie, Funktionen und Nutzung. In: Gerhard Bandow und Hartmut H. Holzmüller (Hg.): "Das ist gar kein Modell". Unterschiedliche Modelle und Modellierungen in Betriebswirtschaftslehre und Ingenieurwissenschaften. 1. Aufl. Wiesbaden: Gabler, S. 3–21.

Töpfer, Armin (2012): Erfolgreich Forschen. Ein Leitfaden für Bachelor-, Master-Studierende und Doktoranden. 3. Aufl. Berlin, Heidelberg: Springer (Springer-Lehrbuch).

Traini, Emiliano; Bruno, Giulia; D'Antonio, Gianluca; Lombardi, Franco (2019): Machine Learning Framework for Predictive Maintenance in Milling. In: *IFAC-PapersOnLine* 52 (13), S. 177–182. DOI: 10.1016/j.ifacol.2019.11.172.

Ulrich, Hans; Dyllick, Thomas; Probst, Gilbert J. B. (Hg.) (1984): Management. Bern, Stuttgart: Haupt (Schriftenreihe Unternehmung und Unternehmungsführung, 13).

van de Kerkhof, Robert M.; Akkermans, Henk A.; Noorderhaven, Nils G. (2016): Knowledge Lost in Data: Organizational Impediments to Condition-Based Maintenance in the Process Industry. In: Henk Zijm, Matthias Klumpp, Uwe Clausen und Michael ten Hompel (Hg.): Logistics and supply chain innovation. Bridging the gap between theory and practice. Cham, Heidelberg, New York, Dordrecht, London: Springer (Lecture Notes in Logistics), S. 223–237. DOI: 10.1007/978-3-319-22288-2_13.

van Tran, Tung; Yang, Bo-Suk (2012): An intelligent condition-based maintenance platform for rotating machinery. In: *Expert Systems with Applications* 39 (3), S. 2977–2988. DOI: 10.1016/j.eswa.2011.08.159.

Villanueva Zacarias, Alejandro Gabriel; Reimann, Peter; Mitschang, Bernhard (2018): A framework to guide the selection and configuration of machine-learning-based data

analytics solutions in manufacturing. In: *Procedia CIRP* 72, S. 153–158. DOI: 10.1016/j.procir.2018.03.215.

Vladova, Gergana; Gronau, Norbert (2022): KI-basierte Assistenzsysteme in betrieblichen Lernprozessen. In: *Industrie 4.0 Management* 2022, S. 11–14. DOI: 10.30844/I40M_22-2_11-14.

W3C (2025): XML Core Working Group Public Page. Online verfügbar unter <https://www.w3.org/XML/Core/>, zuletzt geprüft am 24.02.2025.

Wagner, Carolin; Hellingrath, Bernd (2019): Implementing Predictive Maintenance in a Company: Industry Insights with Expert Interviews. In: 2019 IEEE International Conference on Prognostics and Health Management. San Francisco. Institute of Electrical and Electronics Engineers. Piscataway, New Jersey, S. 1–8. DOI: 10.1109/ICPHM.2019.8819406.

Weber, Peter; Gabriel, Roland; Lux, Thomas; Menke, Katharina (2022): Datenbanksysteme. In: Peter Weber, Roland Gabriel, Thomas Lux und Katharina Menke (Hg.): *Basiswissen Wirtschaftsinformatik*. Wiesbaden: Springer Fachmedien, S. 131–160. DOI: 10.1007/978-3-658-35616-3_6.

Weichert, Dorina; Link, Patrick; Stoll, Anke; Rüping, Stefan; Ihlenfeldt, Steffen; Wrobel, Stefan (2019): A review of machine learning for the optimization of production processes. In: *The International Journal of Advanced Manufacturing Technology* 104 (5-8), S. 1889–1902. DOI: 10.1007/s00170-019-03988-5.

Weidner, Robert (2015): *Technische Unterstützungssysteme*. Unter Mitarbeit von Tobias Redlich und Jens P. Wulfsberg. Berlin, Heidelberg: Spektrum Akademischer Verlag.

Weiß, Christine (2017): Die Zukunft hat begonnen. Pflege 4.0. Technik und Pflege. In: *Praxis Pflegen* 29, S. 11–13.

Wenger, Etienne (2008): *Communities of practice. Learning, meaning, and identity*. Cambridge: Cambridge University Press (Learning in doing).

Wenzel, Sebastian D. (2013): *Nutzungsabhängige Instandhaltung intralogistischer Systeme*. Dortmund: Verlag Praxiswissen (Fabrikorganisation).

Whitehead, Alfred North (1929): The Aims of Education. In: *The Aims of Education and Other Essays*.

Wiemer, Hajo; Drowatzky, Lucas; Ihlenfeldt, Steffen (2019): Data Mining Methodology for Engineering Applications (DMME). A Holistic Extension to the CRISP-DM Model. In: *Applied Sciences* 9 (12), S. 2407. DOI: 10.3390/app9122407.

Wirth, Rüdiger; Hipp, Jochen (2000): CRISP-DM: Towards a Standard Process Model for Data Mining. In: Neil Mackin und Practical Application Company (Hg.):

Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining. Manchester: Practical Application Company.

Wolpert, David H. (1996): The Lack of A Priori Distinctions Between Learning Algorithms. In: *Neural Computation* 8 (7), S. 1341–1390. DOI: 10.1162/neco.1996.8.7.1341.

Wuest, Thorsten; Weimer, Daniel; Irgens, Christopher; Thoben, Klaus-Dieter (2016): Machine learning in manufacturing: advantages, challenges, and applications. In: *Production & Manufacturing Research* 4 (1), S. 23–45. DOI: 10.1080/21693277.2016.1192517.

Zhang, Aston; Lipton, Zachary; Li, Mu; Smola, Alexander J. (2024): Dive into deep learning. Cambridge, New York, Port Melbourne, New Delhi, Singapur: Cambridge University Press.

Zhang, Sheng-Wen; Wang, Zhan; Cheng, De-Jun; Fang, Xi-Feng (2022): An intelligent decision-making system for assembly process planning based on machine learning considering the variety of assembly unit and assembly process. In: *The International Journal of Advanced Manufacturing Technology* 121 (1-2), S. 805–825. DOI: 10.1007/s00170-022-09350-6.

Zhong, Chen; Goel, Sunita (2024): Transparent AI in Auditing through Explainable AI. In: *Current Issues in Auditing* 18 (2), A1-A14. DOI: 10.2308/CIIA-2023-009.

Zhu, Haiyi; Yu, Bowen; Halfaker, Aaron; Terveen, Loren (2018): Value-Sensitive Algorithm Design. In: *Proceedings of the ACM on Human-Computer Interaction* 2, S. 1–23. DOI: 10.1145/3274463.

Zobel, Benedikt; Werning, Sebastian; Metzger, Dirk; Thomas, Oliver (2018): Augmented und Virtual Reality: Stand der Technik, Nutzenpotenziale und Einsatzgebiete. In: Claudia de Witt und Christina Gloerfeld (Hg.): *Handbuch Mobile Learning*. 1. Aufl. Wiesbaden, Heidelberg: Springer VS (Handbuch), S. 123–140. DOI: 10.1007/978-3-658-19123-8_7.

ANHANG

A1: Vergleich der vorgestellten Prozessmodelle

Tabelle 21: Vergleich der vorgestellten Prozessmodelle, eigene Darstellung in Anlehnung an Fayyad et al. (1996), Wirth und Hipp (2000), Azevedo und Santos (2008), Huber et al. (2018), Studer et al. (2021), Schulz et al. (2020), Biegel et al. (2021) und Kubik et al. (2022)

Modell	Ist-Analyse / Soll-Definition	Technische Infrastruktur	Daten- aufnahme	Daten- bewertung	Daten- vorbereitung	Algorithmus- einsatz	Evaluation der Ergebnisse	Verstetigung im Unter- nehmen
KDD	Anwendungs- und Hinter- grundwissen		Zieldatensatz		Datenbereini- gung und -vor- verarbeitung, Datenreduktion	Paradigmen- wahl, Mo- dellauswahl	Data Mining, Ergebnisinter- pretation	Ergebnis- basierte Aktionen
SEMMA			Probieren	Erforschen	Ändern	Modellieren	Bewerten	
CRISP-DM	Geschäftsver- ständnis			Daten- verständnis	Daten- vorbereitung	Modellierung	Evaluation	Umsetzung
DMME	Geschäfts- verständnis	Technisches Verständnis	Technische Realisierung	Daten- verständnis	Daten- vorbereitung	Modellierung	Evaluation	Technische Im- plementierung, Umsetzung
CRISP-ML(Q)	Geschäfts- und Daten- verständnis				Daten- vorbereitung	Modellierung	Evaluation	Umsetzung, Überwachung und Wartung
DASC-PM	Projektauftrag		Daten- bereitstellung	Analyse	Nutzbar- machung	Nutzung		
AIMM	Problemselek- tion, Problem- verständnis, Karte des		Datenaufnahme und Verständnis			Prototypenbau		Umsetzung

Modell	Ist-Analyse / Soll-Definition	Technische Infrastruktur	Daten- aufnahme	Daten- bewertung	Daten- vorbereitung	Algorithmus- einsatz	Evaluation der Ergebnisse	Verstetigung im Unter- nehmen
	aktuellen Zu- stands, Karte des zukünftigen Zu- stands, Projekt- definition							
KDT-EA	Prozess- modellierung		Aufnahme	Vorbereitung	Transformation	Modellierung	Evaluation	Wissensgewinn

A2: Analysevorgehen der Internetrecherche

Die hier angeführte Erläuterung fasst das Vorgehen nach Haselberger (2023) zusammen. Relevante untersuchte Anbieter sind Digital Hubs, Zukunftszentren, KI-Servicezentren, Regionale Kompetenzzentren, Mittelstand-Digital Hauptzentren, Regionalgesellschaften der Industrie- und Handelskammer (IHK) sowie überregionale IHK-Zusammenschlüsse, Bildungszentren und Akademien der IHK, deutsche Hochschulen mit Lernfabriken (Heinze et al. 2021), ProKI-Zentren, Fraunhofer Institute, KI-Wissens- und Weiterbildungszentrum, CyberForum, Bitkom Akademie, Verband für Arbeitsstudien und Betriebsorganisation e.V., Enable AI, Deutsches Forschungszentrum für KI sowie der Verein Deutscher Ingenieure.

Die Anbieter wurden daraufhin auf adäquate Angebote zum Thema ML in der Produktion überprüft. Dabei wurde primär nach einer Kombination der Begriffe „Künstliche Intelligenz“, „KI“, „Maschinelles Lernen“, „Machine Learning“, „ML“, „Deep Learning“, „Data Science“ und „Data Analytics“ sowie „Produktion“ gesucht. In die Analyse wurden dabei Veranstaltungen zwischen dem 01. Januar bis 31. Dezember 2023 aufgenommen. In der Summe konnten 92 Angebote identifiziert werden, welche daraufhin näher untersucht wurden. Die Detailrecherche findet sich zudem bei Rosemeyer und Haselberger (2025).

Tabelle 22: Verteilung der Veranstaltungen nach Anbieter, eigene Darstellung in Anlehnung an Rosemeyer und Haselberger (2025)

Anbieter	Anzahl Angebote
Zukunftszentren	2
Regionale Kompetenzzentren	2
Weitere Transferzentren	2
Netzwerk Mittelstand-Digital	27
Industrie- und Handelskammer	1
Lernfabriken	6
ProKI-Zentren	24
Fraunhofer Institute	12
Weitere Anbieter	16

A3: Durchführung der Kano-Analyse

A3.1: Theorie der Kano-Analyse

Innerhalb des Kano-Modells werden Produktmerkmale anhand der Dimensionen *Kundenzufriedenheit* und *Präsenz der geforderten Eigenschaften* in sechs verschiedene Merkmalsarten eingeordnet. (Shahin und Zairi 2009) Diese lassen sich in Anlehnung an Sauerwein (2000) wie folgt charakterisieren:

- *Basismerkmale*: Sie beschreiben Musskriterien eines Produkts. Ein Nicht-Erfüllen dieser Anforderungen führt zu Unzufriedenheit der Kunden. Hingegen wird deren Erfüllung vorausgesetzt und führt nicht zu erhöhter Zufriedenheit.
- *Leistungsmerkmale*: Bei Leistungsmerkmalen verhält sich die Zufriedenheit proportional zum Erfüllungsgrad. Je höher dieser ist, umso höher die Zufriedenheit. Dasselbe gilt umgekehrt.
- *Begeisterungsmerkmale*: Begeisterungsmerkmale haben den höchsten Einfluss auf die Zufriedenheit mit einem Produkt. Sie werden von Kunden nicht explizit formuliert und oftmals auch nicht erwartet. Eine Erfüllung führt zu überproportionaler Zufriedenheit, während eine Nicht-Erfüllung nicht zu Unzufriedenheit führt.
- *Unerhebliche Merkmale*: Unerhebliche Merkmale haben keinen Einfluss auf die Zufriedenheit der Kunden. Unabhängig von der Erfüllung oder Nichterfüllung ändert sich die Rückmeldung nicht.
- *Rückweisungsmerkmale*: Bei diesen Anforderungen erwarten Kunden das genaue Gegenteil der in der funktionalen Frage formulierten Produkteigenschaft. Dies hat zur Folge, dass die Nichterfüllung zu Zufriedenheit führt und die Erfüllung zu Unzufriedenheit.
- *Fragwürdiges Merkmal*: Eine Einordnung als fragwürdiges Merkmal lässt darauf schließen, dass Fragen von den Probanden falsch verstanden wurden. (Shahin und Zairi 2009)

Zur Einstufung zu ermittelnder Merkmale werden in einem Fragebogen an potenzielle Kunden jeweils zwei Fragen gestellt: je eine *funktionale Frage* (Erfüllung des Merkmals) und eine *dysfunktionale Frage* (Nichterfüllung des Merkmals). Dazu werden fünf Antwortmöglichkeiten gegeben, welche sich von „würde mich sehr freuen“ über „setze ich voraus“, „ist mir egal“, „könnte ich in Kauf nehmen“ bis hin zu „würde mich sehr stören“ erstrecken. (Shahin und Zairi 2009)

A3.2: Fragenkatalog auf Basis des Kano-Modells

Tabelle 23: Funktionale und dysfunktionale Fragen in der Kano-Analyse, eigene Darstellung in Anlehnung an Deutsches Institut für Normung (2020)

Was würden Sie sagen, wenn...

Funktionale Frage	Dysfunktionale Frage
...das Assistenzsystem zu Beginn der Nutzung über die produktionsbezogenen betrachteten Anwendungsfälle aufklärt.	...das Assistenzsystem nicht zu Beginn der Nutzung über die produktionsbezogenen betrachteten Anwendungsfälle aufklärt.
...das Assistenzsystem so viele Aufgaben wie möglich automatisiert ausführt und der Aufwand des Nutzers bei der Datenvorverarbeitung und der Spezifikation eines konkreten KI-Algorithmus damit auf ein Minimum begrenzt wird.	...das Assistenzsystem nur sehr wenige Aufgaben automatisiert ausführt. Der Aufwand des Nutzers bei der Datenvorverarbeitung und der Spezifikation eines konkreten Algorithmus wird damit nicht begrenzt.
...die Darstellung des Assistenzsystems schlank gehalten ist und nur diejenigen Informationen zu sehen sind, die gegenwärtig benötigt werden.	...die Darstellung des Assistenzsystems umfangreich ist und nicht nur diejenigen Informationen zu sehen sind, die gegenwärtig benötigt werden.
...das Assistenzsystem bei technischen Fragestellungen Standardauswahlmöglichkeiten liefert.	...das Assistenzsystem bei technischen Fragestellungen keine Standardauswahlmöglichkeiten liefert.
...das Assistenzsystem Beschreibungen in Bezug auf aktuelle Aufgaben unmittelbar auf dem Bildschirm darstellt, während für theoretische Hintergrundinformationen auf das Internet verwiesen wird.	...das Assistenzsystem sowohl Beschreibungen in Bezug auf aktuelle Aufgaben als auch Hintergrundinformationen unmittelbar auf dem Bildschirm darstellt.
...das Assistenzsystem einen Navigationsverlauf darstellt.	...das Assistenzsystem keinen Navigationsverlauf darstellt.
...das Assistenzsystem eindeutig aufzeigt, welche vom Nutzer eingegebenen Informationen zu einem späteren Zeitpunkt erneut relevant werden und Einfluss auf das Vorgehen haben und welche nicht.	...das Assistenzsystem nicht aufzeigt, welche vom Nutzer eingegebenen Informationen zu einem späteren Zeitpunkt erneut relevant werden und Einfluss auf das Vorgehen haben.
...das Assistenzsystem stets aufzeigt, in welchem Schritt sich der Nutzer befindet. Somit ist leicht ersichtlich, wie viele Schritte absolviert sind und wie viele noch zu gehen sind.	...das Assistenzsystem nicht aufzeigt, in welchem Schritt sich der Nutzer befindet. Somit ist schwer ersichtlich, wie viele Schritte absolviert sind und wie viele noch zu gehen sind.
...der Nutzer, nachdem er eine Eingabe oder Bestätigung getätigt hat, eine Rückmeldung über die erfolgreiche Eingabe erfährt.	...der Nutzer, nachdem er eine Eingabe oder Bestätigung getätigt hat, keine Rückmeldung über die erfolgreiche Eingabe erfährt.
...das Assistenzsystem mehrere Sprachpakete umfasst.	...das Assistenzsystem lediglich ein Sprachpaket umfasst.
...je nach Bedarf Hintergrundinformationen mittels URL verlinkt werden, sodass der Nutzer eine geeignete Internetseite aufrufen kann.	...keine Hintergrundinformationen mittels URL verlinkt werden, sodass der Nutzer keine geeignete Internetseite aufrufen kann.
...das Assistenzsystem auf unterschiedlichen Geräten (Tablet, Laptop, externer Bildschirm) angemessen dargestellt wird.	...das Assistenzsystem auf unterschiedlichen Geräten (Tablet, Laptop, externer Bildschirm) nicht angemessen dargestellt wird.
...zu Beginn der Anwendung die einzelnen zu durchlaufenden Schritte kurz vorgestellt werden.	...zu Beginn der Anwendung die einzelnen zu durchlaufenden Schritte nicht vorgestellt werden.

Funktionale Frage	Dysfunktionale Frage
...das Assistenzsystem dem Benutzer ein Ausprobieren und problemfreies Abändern verschiedener Eingaben und Konfigurationen erlaubt.	...das Assistenzsystem dem Benutzer kein Ausprobieren und problemfreies Abändern verschiedener Eingaben und Konfigurationen erlaubt.
...das Assistenzsystem ein Springen zu einzelnen Schritten aus jedem anderen heraus erlaubt.	...das Assistenzsystem kein Springen zu einzelnen Schritten aus anderen heraus erlaubt.
...das Assistenzsystem Rückmeldungen zu Eingaben des Nutzers liefert, mittels derer er die Folgen seiner Aktionen erlernen kann.	...das Assistenzsystem keine Rückmeldungen zu Eingaben des Nutzers liefert, mittels derer er die Folgen seiner Aktionen erlernen könnte.
...das Assistenzsystem zu jedem Zeitpunkt unterbrochen werden kann.	...das Assistenzsystem nicht zu jedem Zeitpunkt unterbrochen werden kann.
...die Arbeit am Assistenzsystem zu einem späteren Zeitpunkt am Ort des Beendens wieder aufgenommen werden kann.	...die Arbeit am Assistenzsystem nicht zu einem späteren Zeitpunkt am Ort des Beendens wieder aufgenommen werden kann.
...die Eingabe von Text so lange im Textfeld verbleibt, bis der Nutzer die Eingabe bestätigt/übernimmt.	...die Eingabe von Text auch nach Übernahme/Bestätigung im Textfeld verbleibt.
...das Assistenzsystem dem Benutzer das Rückgängigmachen der letzten Eingabe erlaubt.	...das Assistenzsystem dem Benutzer nicht das Rückgängigmachen der letzten Eingabe erlaubt.
...das Assistenzsystem dem Benutzer erlaubt, einführende Informationen bei zukünftigen Schritten zu überspringen.	...das Assistenzsystem dem Benutzer nicht erlaubt, einführende Informationen bei zukünftigen Schritten zu überspringen.
...das Assistenzsystem zuvor eingegebene Informationen, insofern relevant, wieder aufgreift und damit die Bedienung des Assistenzsystem in einem zweiten Anwendungsfall erleichtert.	...das Assistenzsystem zuvor eingegebene Informationen, insofern relevant, nicht wieder aufgreift, womit es zu keiner erleichterten Bedienung des Assistenzsystem in einem zweiten Anwendungsfall kommt.
...das Assistenzsystem den aktuellen Status von Eingaben und Fortschritten im Hintergrund automatisch speichert, um Datenverlust vorzubeugen.	...das Assistenzsystem den aktuellen Status von Eingaben und Fortschritten im Hintergrund nicht automatisch speichert. Datenverlust ist damit möglich.
...das Assistenzsystem fehlerhafte Eingaben am Ende eines jeden Schritts abfängt und das Aufrufen einer Folgeseite verhindert.	...das Assistenzsystem keine fehlerhaften Eingaben am Ende eines jeden Schritts abfängt und nicht das Aufrufen einer Folgeseite verhindert.
...das Assistenzsystem innerhalb einer Seite die Korrektur von vorgenommenen Fehlern zu verschieben erlaubt und zunächst andere Eingaben zu tätigen gewährt.	...das Assistenzsystem innerhalb einer Seite die Korrektur von vorgenommenen Fehlern nicht zu verschieben erlaubt und nicht zunächst gewährt, andere Eingaben zu tätigen.
...das Assistenzsystem den Nutzer auf Eingabefehler hinweist.	...das Assistenzsystem den Nutzer nicht auf Eingabefehler hinweist.
...das Assistenzsystem präzise Fehlertexte bei Eingabefehlern vorgibt.	...das Assistenzsystem keine präzisen Fehlertexte bei Eingabefehlern vorgibt.
...das Assistenzsystem Vorschläge macht, wie Eingabefehler zu korrigieren sind.	...das Assistenzsystem keine Vorschläge macht, wie Eingabefehler zu korrigieren sind.
...das Assistenzsystem Textfelder mit Eingabefehler hervorhebt.	...das Assistenzsystem Textfelder mit Eingabefehler nicht hervorhebt.
...das Assistenzsystem dem Benutzer am Ende eines Schritts Bestätigungen über erfolgreich	...das Assistenzsystem dem Benutzer am Ende eines Schritts keine Bestätigungen über erfolgreich
erledigte Aufgaben anzeigt.	erledigte Aufgaben anzeigt.

Funktionale Frage	Dysfunktionale Frage
erledigte Aufgaben anzeigt und dass es keine offenen Punkte mehr gibt.	
...das Assistenzsystem optisch ansprechend gestaltet ist.	...das Assistenzsystem nicht optisch ansprechend gestaltet ist.
...das Assistenzsystem in einfacher Sprache verfasst ist und für Nicht-KI-Experten verständlich ist.	...das Assistenzsystem nicht in einfacher Sprache verfasst ist und für Nicht-KI-Experten schwer verständlich ist.
...das Assistenzsystem eine Funktion zum Einreichen von Verbesserungsvorschlägen bietet.	...das Assistenzsystem keine Funktion zum Einreichen von Verbesserungsvorschlägen bietet.


A4: Operationalisierungsmethode in BPMN-Darstellung

Abbildung 51: Operationalisierungsmethode gemäß BPMN

A5: Kriterien für die Wahl einer Technologie

Tabelle 24: Kriterien für die Auswahl einer geeigneten Technologie

Kriterium	Laptop	Tablet	Desktop-Computer	Handy	Augmented Reality	Virtual Reality
Mobilität	Hoch	Hoch	Gering	Hoch	Hoch	Mittel
Einfache Nutzung	Hoch	Hoch	Hoch	Hoch	Gering	Gering
Interaktivität	Gering	Gering	Gering	Mittel	Hoch	Hoch
Echtzeit-Assistenz	Hoch	Hoch	Hoch	Mittel	Gering	Gering
Verbreitung in der Produktion	Hoch	Hoch	Mittel	Hoch	Gering	Gering

A6: Übersicht über Busprotokolle und Kommunikationsprotokolle

A6.1: Industrierelevante Busprotokolle

Tabelle 25: Vergleich von Busprotokollen, eigene Darstellung in Anlehnung an PROFIBUS Nutzerorganisation (2025a), PROFIBUS Nutzerorganisation (2025b), Modbus Organization (2006), Deutsches Institut für Normung (2024b) und B&R Industrie Elektronik (2025)²⁴

Protokoll	Eigenschaften	Vorteile	Nachteile
Profinet	Ethernet-basiertes Protokoll	Hohe Datenübertragungsraten	
	Unterstützt Echtzeitkommunikation	Einfache Integration in bestehende Ethernet-Infrastrukturen	Komplexe Implementierung
	Flexibel in der Netzwerktopologie		Hohe Kosten
	Integration von Sicherheitsfunktionen	Unterstützt eine Vielzahl von Anwendungen	
Profibus	Seriellles Feldbusprotokoll	Weit verbreitet in der Industrie	Begrenzte Datenübertragungsraten
	Unterscheidung verschiedener Varianten: Profibus DP (für Datenübertragung), Profibus PA (für Prozessautomatisierung)	Hohe Zuverlässigkeit	Anfällig für physische Beschädigungen
		Hohe Eignung für Echtzeitanwendungen	
Powerlink	Ethernet-basiertes Echtzeitprotokoll	Hohe Echtzeit-Performance	Wenig verbreitet
	Verwendet Standard-Ethernet-Hardware	Lizenzgebührenfrei	Begrenzte Herstellerunterstützung
	Zyklische und azyklische Datenübertragung	Deterministische Datenübertragung	
Modbus	Einfaches und offenes Kommunikationsprotokoll	Einfache Implementierung	Begrenzte Fehlerdiagnosemöglichkeiten
	Für serielle Kommunikation entwickelt, erweitert auf TCP/IP	Weit verbreitet und gut dokumentiert	Langsame Datenübertragung
		Unterstützt verschiedene Geräte über dasselbe Netzwerk	Keine integrierten Sicherheitsfunktionen

²⁴ Zur Unterstützung der Strukturierung der Anhänge A6-A8 wurde in Teilen ChatGPT (OpenAI 2025) verwendet und KI-Generate adaptiert übernommen. Die dabei erstellten Inhalte wurden stets nach bestem Wissen und Gewissen mit Hinblick auf die korrekte Wiedergabe der Primärquellen überprüft. Die Gestaltung der jeweiligen Prompts stellt eine kreative Eigenleistung des Autors dar und ist einsehbar bei Rosemeyer (2025d).

Protokoll	Eigenschaften	Vorteile	Nachteile
MeterBus	Master/Slave-Architektur		
	Serielles Kommunikationsprotokoll	Geringer Energieverbrauch	Niedrige Datenübertragungsrate
	Unterstützt große Netzwerke mit vielen Geräten	Geeignet für lange Distanzen Einfache Topologie und Installation	Begrenzte Bandbreite für komplexe Daten

A6.2: Industrierelevante Kommunikationsprotokolle

Tabelle 26: Übersicht über verschiedene Netzwerkprotokolle, eigene Darstellung in Anlehnung an Mahnke et al. (2009), MQTT.org (2025), MTConnect Institute (2025) und Socolofsky und Kale (1991)

Protokoll	Funktionsweise	Vorteile	Nachteile
MQTT	Protokoll für das Internet of Things und Machine-to-Machine-Kommunikation	Effizient bei geringer Bandbreite	Broker als zentraler Single-Point-of-Failure
	Senden von Nachrichten durch Clients an einen Broker, Weiterleitung durch diesen an Clients	Geringe Latenz Einfache Implementierung	Kein eingebauter Sicherheitsmechanismus Nicht für große Datenmengen optimiert
OPC UA	Service-orientierte Architektur für industrielle Kommunikation	Plattformunabhängig Hohe Sicherheitsmechanismen	Hoher Ressourcenbedarf Komplexe Implementierung
	Ermöglicht semantische Datenmodellierung und sichere Kommunikation	Unterstützt komplexe Datenmodelle und Echtzeitkommunikation	Hohe Latenz im Vergleich zu anderen Protokollen
MT Connect	Offenes Protokoll zur einheitlichen Erfassung und Bereitstellung von Maschinendaten	Standardisierte Datenmodelle	Langsam bei Echtzeitanwendungen
	Nutzt XML für die Strukturierung der Daten	Einfache Integration Keine proprietären Protokolle notwendig	Flexibilität eher gering
TCP/IP	Verbreitetes Netzwerkprotokoll, welches Datenpakete über Netzwerke hinweg transportiert	Weit verbreitet und standardisiert	Zusatzaufwand durch Protokoll-Header Verzögerungen durch Fehlerkorrekturmechanismen
	Gewährleistet zuverlässige Übertragung, Internet Protocol sorgt für spezifische Adressierung	Fehlerkorrektur und zuverlässige Übertragung	Keine integrierte Verschlüsselung

A7: Vergleich der Merkmalsextraktions- und selektionsmethoden

Tabelle 27: Vergleich der vorgestellten Extraktions- und Selektionsmethoden, eigene Darstellung in Anlehnung an Theng und Bhoyar (2024), James et al. (2013), Hastie et al. (2017), Bishop (2006), Murphy (2014) und Shalev-Shwartz (2014)

Methode	Zweck	Typ	Vorteile	Nachteile
ANOVA-F	Vergleicht Mittelwerte von Variablen	Parametrisch	Leicht zu interpretieren	Nimmt normalverteilte Daten an
Mutual Information	Bewertung der Abhängigkeitsintensität zwischen Variablen	Nicht-parametrisch	Erfasst nicht-lineare Zusammenhänge	Schwierige Interpretation bei mehrdimensionalen Daten
LASSO	Geeignet zur Verarbeitung hochdimensionaler Daten	Regressionsmethode	Reduziert Fehler, die durch eine Überanpassung entstehen können	Erfordert sorgfältige Wahl des Regularisierungsparameters
Random Forest Klassifikation	Erzeugte Bäume berechnen Relevanz eines Merkmals	Ensemble-Methode	Robust gegenüber Overfitting	Hoher Rechenaufwand, schwer zu interpretieren
PCA	Dimensionsreduktion	Lineares Verfahren	Reduziert Datenkomplexität	Variabilitätsverlust, schwer zu interpretieren
LDA	Dimensionsreduktion	Lineares Modell	Effektiv bei klar getrennten Klassen	Nimmt normalverteilte Daten an
Factor Analysis	Identifikation latenter Variablen	Explorative Methode	Findet zugrundeliegende Strukturen	Subjektive Interpretation notwendig, Rotation beeinflusst Ergebnisse

A8: Vergleich von Datenbanksystemen und Dateiformaten

A8.1: Vergleich verschiedener Datenbanksysteme

Tabelle 28: Vergleich von Datenbanksystemen, eigene Darstellung in Anlehnung an Bitkom (2014), Weber et al. (2022) und Bader et al. (2017)

Speichersystem	Funktionsweise	Vorteile	Nachteile
Relationale Datenbank	Speichert Daten in Tabellen mit vordefiniertem Schema Verwendet SQL für Abfragen	Hohe Datenkonsistenz Weit verbreitet	Skalierungsprobleme bei großen Datenmengen Schema kann Anpassungen erschweren
NoSQL-Datenbank	Nutzt flexible Datenmodelle (Dokumenten-, Spalten-, Key-Value- oder Graph-Datenbanken) Zumeist horizontal skalierbar	Hohe Skalierbarkeit Flexibel für unstrukturierte oder semi-strukturierte Daten	Geringe Standardisierung
In-Memory-Datenbank	Speichert und verarbeitet Daten direkt im Hauptspeicher statt auf Festplatten	Sehr schnelle Abfragen Gut geeignet für Echtzeit-Anwendungen.	Hoher Hauptspeicherbedarf Datenverlust bei Systemausfall möglich
Data Warehouses	Optimiert für analytische Abfragen Speichert große Mengen historischer Daten in strukturierter Form.	Effiziente Datenanalyse Unterstützt komplexe Abfragen Hohe Datenqualität	Hoher Speicherbedarf Langsame Echtzeitverarbeitung Komplexer Aufbau
Zeitreihendatenbank	Datenzeilen bestehen aus einem Zeitstempel und Werten Mehrere Zeilen von Zeitreihendaten werden gruppiert gespeichert Abfragen enthalten Zeitstempel oder Zeitbereiche	Effiziente Speicherung und Abfrage von Zeitreihendaten Schnelle Aggregationen von Zeitbereichen	Begrenzte Standardisierung Hoher Speicherbedarf
Objektorientierte Datenbank	Speichert Daten als Objekte in einer Hierarchie Integriert sich in objektorientierte Programmiersprachen	Gut geeignet für komplexe Datenstrukturen	Weniger verbreitet Begrenzte Standardisierung Oft schlechte Performance bei einfachen Abfragen

A8.2: Bewertung der angeführten Dateiformate

Tabelle 29: Vergleich von JSON, XML und CSV, eigene Darstellung in Anlehnung an W3C (2025), Bray et al. (2008), ECMA International (2017) und Mozilla Foundation (2025)

Kriterium	CSV	JSON	XML
Struktur	Flache Tabellenstruktur	Hierarchische Schlüssel-Wert-Paare	Hierarchische Markups mit Tags
Lesbarkeit	Einfach für Menschen und Maschinen	Einfach für Menschen und Maschinen	Schwer für Menschen, leicht für Maschinen
Datenhierarchie	Keine Unterstützung für Hierarchien	Unterstützt verschachtelte Strukturen	Unterstützt komplexe Hierarchien
Speicherbedarf	Sehr gering	Mittel	Hoch
Unterstützte Datentypen	Nur Zeichenketten, keine nativen Typen	Unterstützt Zahlen, Strings, Arrays, Objekte	Keine nativen Datentypen, alle Werte sind Strings
Flexibilität	Gering	Sehr flexibel	Sehr flexibel
Vorteile	Einfach zu erstellen und zu lesen	Leicht verständlich und weit verbreitet	Unterstützt sehr komplexe und strukturierte Daten Standard für viele ältere Systeme
	Sehr effizient in Bezug auf Speicherplatz	Unterstützt komplexe Datenstrukturen	
	Schnell zu verarbeiten	Native Unterstützung in JavaScript und vielen Programmiersprachen	
Nachteile	Keine Hierarchien oder Verschachtelungen	Mittlerer Speicherbedarf	Hoher Speicherbedarf Langsame Verarbeitung
	Keine Unterstützung für komplexe Datentypen		
	Fehleranfällig, z. B. bei Kommas in Werten		

A9: Vollständige Kompetenztabelle

Tabelle 30: Vollständige Kompetenztabelle, eigene Darstellung in Anlehnung an Abel et al. (2013) und Abele et al. (2015a)

Hauptkompetenz	Teilkompetenz	Handlung	Professionswissen	Konzeptionelles Wissen	Taxonomiestufe	Nummer Teilkompetenz
Fähigkeit, ML-Grundlagen zu verstehen und zu erklären	Fähigkeit, grundlegende Begriffe im Kontext von ML-Anwendungen beschreiben zu können	KI und ML definieren können, Lernparadigmen nennen und beschreiben können	Kenntnis über Definitionen von KI und ML Kenntnis über verschiedene Lernparadigmen Kenntnis über Treiber für ML-Anwendungen (Speicheranwendungen, Prozessoren, Datenmenge, uvm.)	Verständnis, warum sich v.a. Supervised und Unsupervised Learning in der Produktion eignen	Verstehen	TK 1
	Fähigkeit, in der eigenen Produktion aufgezeichnete Daten mit Hinblick auf deskriptive Statistik erklären zu können	Erkenntnisse aus der Bewertung von Trends, Minima, Maxima, usw. können identifiziert werden, Beschreibung erfolgt anhand dieser Parameter	Kenntnis über Lageparameter und Streuungsmaße Kenntnis über weitere beschreibende Merkmale (gleitender Durchschnitt, u.a.)	Verständnis über die Verläufe von Sensorwerten	Anwenden	TK 2
Fähigkeit, Datenverläufe und Modellergebnisse zu beurteilen	Fähigkeit, Ergebnisse von ML-Modellen zu verstehen und faktenbasiert einzuschätzen	Erkenntnisse anhand Leistungskennzahlen faktenbasiert einordnen können	Kenntnis über Evaluationsmetriken	Verständnis, warum Ergebnisse „schlecht“ sein könnten	Evaluieren	TK 3
	Fähigkeit, Datensatz für ML-Modell mit hoher Quantität und Qualität anzufertigen	Datensatz ist vollständig erstellt, Datensatz enthält keine zufälligen Ausreißer, Datensatz enthält Trends und klar ersichtlichen n.i.O.-Bereich	Kenntnis über die Idee hinter „Garbage in / Garbage out“ Grobe Kenntnis über Schritte zur Datenvorverarbeitung	Verständnis, dass Daten unabdingbare Voraussetzung für ML-Anwendungen sind	Anwenden	TK 4

Hauptkompetenz	Teilkompetenz	Handlung	Professionswissen	Konzeptionelles Wissen	Taxonomiestufe	Nummer Teilkompetenz
Fähigkeit, ML-Anwendungsmöglichkeiten im eigenen Arbeitsbereich zu identifizieren	Fähigkeit, verschiedene potenzielle Anwendungsfälle für ML in der Produktion aufzuzählen	Gebräuchliche Anwendungsfälle in der Produktion (Zustandsüberwachung, prädiktive Instandhaltung, prädiktive Qualitätssicherung,...) nennen	Kenntnis über Grundlagen von Anwendungsfällen in der Produktion (Zustandsüberwachung, prädiktive Instandhaltung, Verbesserung der Bauteilqualität, ... Kenntnis über potenzielle Anwendungsbereiche (z.B. diverse Werkzeugmaschinen)		Erinnern	TK 5
	Fähigkeit, Anwendungsfälle in der eigenen Produktionsumgebung zu illustrieren	Anwendungsfälle in der eigenen Produktion einordnen können	Kenntnis über Anwendungsfälle in der eigenen Produktion	Verständnis, warum sich einzelne Anwendungsfälle besser eignen als andere	Anwenden	TK 6
Fähigkeit, grundlegende ML-Modelle zu nutzen	Fähigkeit, Funktionsweise „einfacher“ ML-Algorithmen darstellen zu können	Verschiedene Algorithmen nennen Einen Algorithmus in eigenen Worten wiedergeben	Grobe Kenntnis über Vor- und Nachteile sowie Funktionsweise gebräuchlicher Algorithmen		Verstehen	TK 7
	Fähigkeit, den richtigen Algorithmus aus vorgegebener Auswahl auszuwählen	Algorithmus mit besten ML-Metriken auswählen	Kenntnis über verschiedene Evaluationsmetriken	Verständnis, warum einzelne Algorithmen besser geeignet sind als andere	Anwenden	TK 8
Fähigkeit, interdisziplinäre Kommunikation zielorientiert (IT,	Fähigkeit, bereichsübergreifenden Austausch mit Hinblick auf ML-Anwendungen zielorientiert zu	Zielorientiertes Vorgehen mit Fokus auf ML-Anwendung: richtigen Ansprechpartner	Kenntnis, wie mit weiteren Abteilungen zu kommunizieren ist	Verständnis, welchen Beitrag welche Abteilung zum Projekt liefern kann	Evaluieren	TK 9

Hauptkompetenz	Teilkompetenz	Handlung	Professionswissen	Konzeptionelles Wissen	Taxonomie- stufe	Nummer Teilkompetenz
Management,...) zu gestalten	gestalten (u.a. mit der IT- Abteilung, Vorgesetzten,...)	identifizieren, Aufgaben richtig delegieren				
	Fähigkeit, notwendige Schritte bei der Einführung von ML-Anwendungen zu erläutern	Min. ein Vorgehensmodell mit Namen nennen Schritte des Modells auf- zeichnen können	Kenntnis über Grundlagen von Vorgehensmodellen Kenntnis über die einzelnen Schritte des Modells	Verständnis, warum die Verwendung ei- nes Vorgehensmo- dells von Vorteil ist	Verstehen	TK 10
	Fähigkeit, notwendige Schritte bei der Einführung strukturiert anzuwenden	Strukturiertes Bearbeiten eines ML-Projekts anhand eines Vorgehensmodells	Kenntnis über Grundlagen von Vorgehensmodellen Kenntnis über die einzelnen Schritte des Modells	Verständnis, warum die Verwendung ei- nes Vorgehensmo- dells von Vorteil ist	Anwenden	TK 11
Fähigkeit, ML- Projekte struktu- riert durchzufüh- ren	Fähigkeit, notwendige Vo- raussetzungen (Sensoren, Netzwerkinfrastruktur,...) für die eigene Produktion zu identifizieren	Sensorarten für das gege- bene Problem aufzählen und geeignete auswählen	Kenntnis, welche Sensorarten existieren Kenntnis, welche Sensor- werte im eigenen Unterneh- men aufgezeichnet werden können	Verständnis, welche Sensoren sich für das eigene Problem eignen und welche nicht Verständnis, warum einzelne Sensoren sich (nicht) eignen	Analysieren	TK 12

A10: Verhaltensanker für die Beobachtung

Tabelle 31: Verhaltensanker in der Beobachtung

Korrespondierende Handlung	V0	V1	V2	V3
Erkenntnisse aus der Bewertung von Trends, Minima, Maxima, usw. können identifiziert werden, Beschreibung erfolgt anhand dieser Parameter	TN kann aufgezeichnete Daten nicht mit deskriptiver Statistik erklären	TN kann aufgezeichnete Daten nur schwer mit deskriptiver Statistik erklären	TN kann aufgezeichnete Daten weitestgehend mit deskriptiver Statistik erklären	TN kann aufgezeichnete Daten problemfrei mit deskriptiver Statistik erklären
Erkenntnisse anhand Leistungskennzahlen faktenbasiert einordnen können	TN kann Erkenntnisse nicht faktenbasiert einordnen	TN kann Erkenntnisse nur schwer und in geringer Anzahl faktenbasiert einordnen	TN kann Erkenntnisse weitestgehend faktenbasiert einordnen	TN kann Erkenntnisse leicht und in hoher Anzahl faktenbasiert einordnen
Datensatz ist vollständig erstellt, Datensatz enthält keine zufälligen Ausreißer, Datensatz enthält Trends und klar ersichtlichen n.i.O.-Bereich	TN kann die Anforderungen an den Datensatz nicht umsetzen	TN kann die Anforderungen an den Datensatz nur schwer umsetzen	TN kann die Anforderungen an den Datensatz weitestgehend umsetzen	TN kann die Anforderungen an den Datensatz vollumfänglich umsetzen
Anwendungsfälle in der eigenen Produktion einordnen können	TN kann Anwendungsfälle nicht illustrieren	TN kann Anwendungsfälle nur schwer illustrieren	TN kann Anwendungsfälle weitestgehend illustrieren	TN kann Anwendungsfälle gut und schnell illustrieren
Algorithmus mit besten ML-Metriken auswählen	TN kann keinen Algorithmus auswählen	TN kann Auswahl des richtigen Algorithmus nur schwer vornehmen	TN kann Auswahl des richtigen Algorithmus weitestgehend vornehmen	TN kann Auswahl des richtigen Algorithmus leicht vornehmen
Zielorientiertes Vorgehen mit Fokus auf ML-Anwendung: richtigen Ansprechpartner identifizieren, Aufgaben richtig delegieren	TN kann keinen zielorientierten Austausch gestalten	TN kann zielorientierten Austausch nur schwer gestalten	TN kann zielorientierten Austausch weitestgehend gestalten	TN kann zielorientierten Austausch gut gestalten
Strukturiertes Bearbeiten eines ML-Projekts anhand eines Vorgehensmodells	TN geht Bearbeitung unstrukturiert an	TN geht Bearbeitung nur geringfügig strukturiert an	TN geht Bearbeitung weitestgehend strukturiert an	TN geht Bearbeitung vollständig strukturiert an

Korrespondierende Handlung	V0	V1	V2	V3
Sensorarten für das gegebene Problem aufzählen und geeignete auswählen	TN kann geeignete Sensoren nicht identifizieren	TN kann geeignete Sensoren nur schwer identifizieren	TN kann geeignete Sensoren weitestgehend identifizieren	TN kann geeignete Sensoren leicht identifizieren

A11: Fragen des LeistungstestsAufgabe 1: Grundlagen von ML-Anwendungen (14P)

- a) Nennen Sie Ihnen bekannte Lernparadigmen von ML-Anwendungen. (3P)
- b) Erklären Sie die grobe Funktionsweise von zwei der Lernparadigmen in eigenen Worten. (4P)
- c) Nennen Sie für zwei der genannten Lernparadigmen mögliche Modelle (keine Algorithmen). (2P)
- d) Nennen Sie drei ML-Algorithmen. (3P)
- e) Erklären Sie die Funktionsweise einer der Algorithmen aus der vorherigen Teilaufgabe in eigenen Worten. (2P)

Aufgabe 2: Implementierung in der Produktion (9P)

- a) Nennen Sie drei Anwendungsmöglichkeiten für ML-Anwendungen in der Produktion. (3P)
- b) Zeichnen Sie ein Vorgehensmodell samt relevanter Schritte auf. Nennen Sie zusätzlich den Namen des Modells. (6P)

A12: Betreute Abschlussarbeiten

Im Rahmen der Erstellung dieser Arbeit sind vom Autor zahlreiche studentische Arbeiten betreut worden. Nachfolgend werden solche studentischen Arbeiten genannt, die detaillierte Informationen und Vorarbeiten als Ergänzung zu dieser Arbeit enthalten.

Tabelle 32: Übersicht über betreute Abschlussarbeiten

Name	Art	Titel
Cem Akbal	Masterthesis	Entwicklung eines Bewertungssystems über den Automatisierungsgrad von KI-Implementierungslösungen
Laurenz Beck	Masterthesis	Technische Implementierung einer niedrighschwelligen Instruktion für den Einsatz von Machine Learning Anwendungen im Produktionsumfeld kleiner und mittelständischer Unternehmen
Ann-Kathrin Bischoff	Bachelorthesis	Systematische Analyse von Anforderungen an die Interaktion von Produktionsmitarbeitern und KI-Systemen
Anil Erol	Bachelorthesis	Recherche von Anwendungsfällen zur Zusammenarbeit von Produktionsmitarbeitern und KI
Josef Gallus	Masterthesis	Technische Weiterentwicklung eines Assistenzsystems zur operativen Realisierung von KI an einer Profilieranlage
Oleksiy Gavrylets	Masterthesis	Menschzentrierte Weiterentwicklung eines Assistenzsystems zur operativen Realisierung von maschinellem Lernen in der Produktion
Jana Haselberger	Masterthesis	Weiterbildungsangebote für KI in der Produktion: aktueller Stand und zukünftige Ausrichtung
Jiahe Mao	Bachelorthesis	Human-centered further development of a cognitive assistance system based on the DIN EN ISO 9241 series of standards
Vincent Müller	Masterthesis	Entwicklung einer Methodik zur Einführung Künstlicher Intelligenz in der Produktion
Jan Riehl	Masterthesis	Systematische Literaturrecherche zu automatisierten Einführungsrichtlinien für KI in der Produktion
Joseph Thorwest	Bachelorthesis	Entwicklung eines Workshops auf Basis des problembasierten Lernens zur Einführung von maschinellem Lernen in der Produktion
Slim Ben Sassi, Jana Dorer, Jovan Hussan, David Pirkl, Lena Schäfer	Bachelorpraktikum Informatik	CAS-Machine Learning Anwendung - Assistenzsystem für Nicht-Expert:innen

A13: Publikationsübersicht

Im Rahmen der vorliegenden Dissertation wurden unter Mitwirkung des Autors die nachfolgenden wissenschaftlichen Publikationen erstellt. Diese enthalten detaillierte Informationen und Vorarbeiten zu der Arbeit.

Tabelle 33: Publikationen mit Vorarbeiten zu dieser Dissertation

Quelle	Titel	Typ
Metternich et al. (2021)	Künstliche Intelligenz zur Umsetzung von Industrie 4.0 im Mittelstand: Expertise des Forschungsbeirats der Plattform Industrie 4.0	Fachbeitrag
Rosemeyer et al. (2021)	Künstliche Intelligenz für KMU: Ein Leitfaden zur Einführung von KI im Produktionsumfeld	Fachbeitrag
Rosemeyer et al. (2022)	Towards artificial intelligence in production: A competence profile for shop floor managers	Konferenzbeitrag
Nixdorf et al.	Work-Based Learning in Manufacturing Industry. A Sector-Based Meta-Analysis	Fachbeitrag
Rosemeyer et al. (2023)	A Cognitive Assistance System To Support The Implementation Of Machine Learning Applications In Manufacturing	Konferenzbeitrag
Rosemeyer und Metternich (2023)	Weiterbildung und Wertschöpfung an einem Ort: Neues betriebliches Lernen für KI-Anwendungen in der Produktion	Fachbeitrag
Rosemeyer und Metternich (2024)	Human-Centered Design for Digital Machine Learning Assistance Systems in Work-Based Learning	Konferenzbeitrag
Rosemeyer et al. (2024a)	A maturity model for digital ML tools to be used in manufacturing environments	Report
Rosemeyer et al. (2024b)	Digital Assistance Systems to Implement Machine Learning in Manufacturing: A Systematic Review	Zeitschriftenaufsatz