

**UNIVERSITÄT
BAYREUTH**

**UNIVERSITÄT BAYREUTH
INSTITUT FÜR INFORMATIK**

Verbesserung von Prozessmodellen durch relevante Prozessdetails

Von der Universität Bayreuth
zur Erlangung des Grades eines
Doktors der Naturwissenschaften (Dr. rer. nat.)
genehmigte Abhandlung

von

Myriel Katrin Fichtner

aus Bayreuth

1. Gutachter: Prof. Dr.-Ing. Stefan Jablonski
 2. Gutachter: Prof. Dr. Maximilian Röglinger
- Tag der Einreichung: 15. März 2024
Tag des Kolloquiums: 19. Juni 2024

ZUSAMMENFASSUNG

Prozessmodellierung ist eine etablierte Methode zur Visualisierung und Dokumentation von internen und externen Abläufen in Unternehmen. Die dadurch entstehenden Prozessmodelle beschreiben Arbeitsschritte, die zur Erfüllung eines Unternehmensziels notwendig sind. Darin sind außerdem Arbeitsanweisungen für Mitarbeitende enthalten, die während der Prozessausführung umgesetzt werden müssen. Aus diesem Grund sind informationsreiche und klar verständliche Prozessmodelle entscheidend für erfolgreiche Abläufe.

Allerdings sind Prozessmodellierenden nicht immer alle Ausführungsdetails eines Prozesses bekannt oder sie können die Details aufgrund der beschränkten Ausdruckskraft von Modellierungssprachen nicht adäquat in das Modell integrieren. In anderen Fällen wird zur Vermeidung komplexer und unverständlicher Modelle Prozessinformation weggelassen oder abstrahiert. In der Konsequenz sind Aufgabenbeschreibungen zu generisch und es fehlen essenzielle Ausführungsinformationen im Prozessmodell. Dies kann zu Abweichungen in den Prozessergebnissen führen, z.B. hinsichtlich der Produktqualität. Die Identifikation der Ursachen solcher Abweichungen sowie die Bestimmung notwendiger Modellanpassungen zur Steigerung des Prozessersfolgs in zukünftigen Ausführungen stellen anspruchsvolle Herausforderungen dar. Insbesondere wenn die Prozessdetails unbekannt sind, ist die Unterstützung entsprechender Analysemethoden erforderlich.

In der vorliegenden Dissertation wird diese Problemstellung adressiert und ein ganzheitlicher Ansatz zur Verbesserung von Prozessmodellen durch Berücksichtigung relevanter Prozessdetails vorgestellt. Dabei ergänzen relevante Prozessdetails Aufgabenbeschreibungen in bereits modellierten Prozessschritten um Bedingungen. Diese müssen während der Ausführung erfüllt werden, um den Prozessersfolg insgesamt zu steigern. Das entwickelte Gesamtkonzept beschreibt einen inkrementellen Verbesserungsansatz mit welchem Prozessmodelle sukzessive hinsichtlich relevanter Prozessdetails analysiert werden. Dafür werden Ausführungsdaten aus verschiedenen Datenquellen berücksichtigt, was die Entdeckung auch noch unbekannter, aber relevanter Details ermöglicht. Die Anreicherung der Aufgabenbeschreibungen unter Verwendung der analysierten Prozessdetails erfolgt mit einem Fokus auf einer intuitiv verständlichen Repräsentation. Damit wird die inhaltliche Erweiterung von Modellen unter Bewahrung ihrer Lesbarkeit nachhaltig unterstützt.

Zur Konzeption und Umsetzung des Ansatzes werden in dieser Arbeit verschiedene Forschungsrichtungen aufgegriffen und innovativ miteinander verknüpft. Die effektive Anwendbarkeit wesentlicher Schritte wird am Beispiel eines Herstellungsprozesses unter Verwendung von Bilddaten demonstriert. Daneben illustrieren weiterführende Experimente die Anpassungsfähigkeit des Gesamtkonzepts für einen gewinnbringenden Einsatz im Kontext verschiedener Prozesse und Domänen.

ABSTRACT

Process modeling is an established method to visualize and document internal and external workflows within organizations. The resulting process models describe necessary work steps to achieve a certain business goal. Additionally, they contain instructions for employees that must be implemented during process execution. To this end, easily understandable process models with high information content are a key factor for successful process executions.

However, process designers may not always be aware of all execution details of a process. In other cases, the limited expressive power of modeling languages inhibits their ability to adequately integrate certain details into a process model. Furthermore, process information is omitted or abstracted to avoid complex and incomprehensible process models. As a consequence, task descriptions tend to be too generic, lacking essential execution information in the model. This can lead to deviations in process outcomes, such as product quality issues. Identifying the root causes of these deviations and determining necessary model adjustments to enhance process success in future executions are challenging tasks. Especially when process details are unknown, the support of appropriate analysis methods is essential.

The thesis addresses this research gap and introduces a holistic approach to improve process models by considering relevant process details. Relevant process details complement task descriptions in previously modeled process steps with conditions. These must be fulfilled during execution to enhance overall process success. The developed concept describes an incremental optimization approach, where process models are successively analyzed regarding relevant process details. Execution data from various data sources are considered, enabling the discovery of previously unknown but relevant process details. The enrichment of task descriptions using analyzed process details is carried out with a focus on an intuitively understandable representation. This simultaneously supports the increase of information content of a process model while preserving its readability.

To conceptualize and implement the approach, various research directions are integrated innovatively in this work. The applicability of core steps within the concept is demonstrated using an exemplary manufacturing process and image datasets. Further experiments illustrate how the developed concept can be adapted to support its application for process improvement in different domains.

DANKSAGUNGEN

Ich möchte mich hiermit herzlich bei allen Personen bedanken, die mich in meinem Promotionsvorhaben und in der damit verbundenen Lebensphase unterstützt haben.

Dabei gilt allen voran ein besonderer Dank meinem Doktorvater Prof. Dr.-Ing. Stefan Jablonski, der mir einen Rahmen geschaffen hat, in dem ich meinem Wunsch nach einer wissenschaftlichen Tätigkeit nachgehen konnte. Neben meiner Zeit am Lehrstuhl, in der er sich stets für eine positive Arbeitsatmosphäre einsetzte, stand er mir trotz örtlicher und beruflicher Veränderungen mit der nötigen fachlichen und organisatorischen Unterstützung zur Seite. Außerdem möchte ich mich bei Prof. Dr. Maximilian Röglinger bedanken, der die Rolle des Zweitgutachters übernahm und dessen fachliche Expertise meine Dissertation abgerundet hat.

Ein herzliches Dankeschön gilt auch all meinen Kollegen; brillante Wissenschaftler, mit denen der Austausch von Ideen und interessanten Diskussionen neue Impulse lieferten, die entscheidend für die Entwicklung meiner Arbeit waren. Aus den zunächst rein kollegialen Beziehungen sind zahlreiche wertvolle Freundschaften hervorgegangen, über die ich vermutlich seitenweise individuelle Danksagungen verfassen könnte. Meine Kollegen sind für mich immer ein Motivator gewesen, auch in schwierigen Zeiten an meinem Ziel festzuhalten, wofür ich ihnen außerordentlich dankbar bin. Namentlich erwähnen möchte ich an dieser Stelle Sebastian Petter, der nicht nur mein wissenschaftlicher Sparringspartner, sondern auch ein guter Freund wurde, der bis heute immer ein offenes Ohr für mich hat. Ein besonderer Dank geht auch an Prof. Dr. Stefan Schönig und Christian Sturm, die mich außerordentlich in der Einstiegsphase am Lehrstuhl unterstützt und somit die Weichen meiner Forschungstätigkeit gestellt haben. Außerdem danke ich Sascha Sucker und Dr. Dominik Riedelbauch für die produktive und interdisziplinäre Zusammenarbeit, die für meine Forschung sehr wichtig war und in der ich viel lernen durfte. Darunter vor allem, dass durch Zusammenhalt und Begeisterung aus zunächst kleinen Ideen große Werke entstehen können, auf die ich immer wieder gerne zurückblicke.

Auch meinen außeruniversitären Freunden und Freundinnen möchte ich meinen aufrichtigen Dank aussprechen. Sie haben mich trotz der seit letztem Jahr bestehenden räumlichen Distanz dazu motiviert, konsistent an meiner Dissertation weiterzuarbeiten und mich auch unabhängig von der Arbeit durchgehend unterstützt. Ein besonderer Dank gilt Dilara Akbaba, eine inspirierende Powerfrau und stets empathische ZuhörerIn, die vor allem in der letzten Phase meiner Dissertation mitfiebernd an meiner Seite stand.

Ein sehr großer Dank gilt meiner Familie, die immer für mich da ist und mich bedingungslos unterstützt und fördert. Darunter danke ich insbesondere meiner Mutter, die mir mit ihrem unermüdlichen Durchhaltevermögen und ihrer einfühlsamen Art stets als

Vorbild dient und meine Begeisterung für Wissenschaft und Technik geweckt hat. Außerdem möchte ich meinen beiden Brüdern, mit denen ich während meiner Tätigkeit an der Universität sowohl projektbezogen als auch wissenschaftlich zusammenarbeiten durfte, ein herzliches Dankeschön aussprechen. Dabei möchte ich mich ausdrücklich bei meinem Bruder Urs Fichtner für seinen unglaublich wertvollen Einsatz vor allem in der Abschlussphase meiner Dissertation bedanken. Er ist ein herausragender Wissenschaftler, der sich trotz seiner eigenen Aufgaben immer wieder für mich Zeit genommen hat, mir konstruktives Feedback zu meiner Arbeit zu geben und ist mir dabei stets mit Wertschätzung und Anerkennung begegnet.

Abschließend möchte ich mich von ganzem Herzen bei Josua Bloëß bedanken. Er hat mich hinsichtlich unzähliger Aspekte in den letzten Jahren unterstützt, was für mich ausschlaggebend für den Erfolg meiner Promotion war. Dabei meisterte er mit mir den nicht immer ganz einfachen Alltag und hat mir vor allem auch in stressigen und schweren Phasen geduldig zugehört. Er stand mir nicht nur im Kontext von fachlichen Diskussionen mit Rat und Tat zur Seite, sondern bekämpfte mit mir insbesondere immer wieder aufkommende Zweifel und Sorgen. Ohne ihn hätte ich vermutlich niemals den Weg einer Promotion in der Informatik eingeschlagen und vor allem nicht den Mut gehabt, mich den damit verbundenen Hürden zu stellen.

Un cordial merci à tous!

Diese Promotion wurde im Rahmen des Exzellenzclusters „Africa Multiple“ der Universität Bayreuth gefördert.

“The details are not the details. They make the design.”

Charles Eames (1907-1978)
Architekt und Designer

INHALTSVERZEICHNIS

1	EINFÜHRUNG UND PROBLEMSTELLUNG	1
1.1	Prozessmanagement	2
1.1.1	Prozesslebenszyklus	2
1.1.2	Prozessmodellierung und Perspektiven	5
1.2	Herausforderungen in der Prozessmodellierung	10
1.2.1	Anforderungen an effektive Prozessmodelle	10
1.2.2	Ursachen unvollständiger Prozessmodelle	12
1.2.3	Relevante Prozessdetails	14
1.3	Forschungsmethodik	17
1.4	Lösungsansatz und Beitrag	20
1.4.1	Analyse relevanter Prozessdetails	22
1.4.2	Integration relevanter Details in Prozessmodelle	22
1.4.3	Übertragbarkeit in verschiedene Domänen	23
1.5	Aufbau der Arbeit	25
2	GRUNDLEGENDE ANSÄTZE ZUR PROZESSMODELLVERBESSERUNG	27
2.1	Inhaltliche Verbesserung	27
2.1.1	Prozessmodellanalyse	28
2.1.2	Process Mining	29
2.2	Verbesserung der Lesbarkeit	30
2.2.1	Modellierungssprachen und Darstellungsformate	30
2.2.2	Abstraktion und Aggregation	32
2.3	Zusammenfassung	33
3	GESAMTKONZEPT ZUR VERBESSERUNG VON PROZESSMODELLEN DURCH RELEVANTE PROZESSDETAILS	35
3.1	Hintergrund	35
3.2	Drei Phasen des Gesamtkonzepts	37
3.3	Schritte der Verbesserungsphase	40
3.3.1	Aufgabenfilterung	41
3.3.2	Aufgaben- und Datenselektion	42
3.3.3	Ausführung und Labeling	43
3.3.4	Analyse	44
3.3.5	Annotation	46
3.4	Annahmen und Rahmenbedingungen zur Anwendung	48
3.5	Datentypen und Sensorik	49

3.6	Zusammenfassung	52
4	UMSETZUNG DES ANALYSESCHRITTS AM BEISPIEL VON BILDDATEN	53
4.1	Motivierendes Beispiel und Grundidee	54
4.2	Vorteile von Bilddaten	55
4.3	Experimentaufbau	56
4.3.1	Beispielprozess Metallspritzgussverfahren	57
4.3.2	Szenarien und Experimenteller Rahmen	59
4.4	Analyse unstrukturierter Bilddaten mit XAI	63
4.4.1	Einführung in künstliche Intelligenz und XAI	63
4.4.2	Local-Interpretable Model-Agnostic Explanations	69
4.4.3	Umsetzung mit LIME	71
4.4.4	Experimente und Evaluation	77
4.4.5	Ergebnisse	78
4.5	Analyse strukturierter Bilddaten mit Data Mining	84
4.5.1	Einführung in KDD und Data Mining	84
4.5.2	Association Rule Mining	87
4.5.3	Umsetzung mit Association Rule Mining	90
4.5.4	Experimente und Evaluation	93
4.5.5	Ergebnisse	99
4.6	Vergleich der entwickelten Ansätze und Diskussion	103
4.7	Zusammenfassung	104
5	ERSTELLUNG DER AUFGABENANNOTATIONEN	107
5.1	Bisherige Studien zur Verständlichkeit von Prozessmodellen	108
5.2	Experimentelle Studie zur Bewertung von Aufgabenannotationen	110
5.2.1	Verständlichkeit und Intuitivität	110
5.2.2	Studiendesign, Forschungsfragen und Hypothesen	112
5.2.3	Messinstrumente und Aufgaben	114
5.2.4	Durchführung der Studie und Ablauf	122
5.3	Ergebnisse der experimentellen Studie	124
5.3.1	Deskriptive Statistik	124
5.3.2	Statistische Hypothesenprüfung	131
5.3.3	Beantwortung der Forschungsfragen der Studie	135
5.3.4	Diskussion	135
5.4	Umwandlung relevanter Details in Aufgabenannotationen und Integration	137
5.4.1	Nachverarbeitung und Umwandlung relevanter Prozessdetails	137
5.4.2	Ergänzung von Prozessmodellen um Aufgabenannotationen	138
5.5	Zusammenfassung	140
6	ÜBERTRAGBARKEIT DES KONZEPTS IN WEITERE DOMÄNEN AM BEISPIEL DER ROBOTIK	143
6.1	Domänen- und prozessspezifische Anpassungen des Gesamtkonzepts	144
6.2	Prozessmodelle in der Robotikdomäne	148
6.2.1	Terminologische Abgrenzungen und Hintergrund	148
6.2.2	Modellierung von Roboteraufgaben mit Präzedenzgraphen	150

6.2.3	Ausführung von Aufgabenmodellen durch Roboter	154
6.3	Erweiterung von Roboterprozessmodellen um relevante Details	156
6.3.1	Anpassung der Verbesserungsphase	156
6.3.2	Verfeinerung der Objektvorlagen	158
6.4	Experimente, Evaluation und Ergebnisse	160
6.4.1	Szenarien und Aufbau	160
6.4.2	Implementierung und prozessspezifische Annahmen	163
6.4.3	Ergebnisse	165
6.5	Diskussion und weitere Anwendungsgebiete	169
6.6	Zusammenfassung	171
7	VERWANDTE ARBEITEN UND EINORDNUNG	173
7.1	Intrinsische und extrinsische Prozessmodellverbesserung	173
7.2	Process Mining als extrinsisches Verfahren zur Modellverbesserung	174
7.2.1	Multiperspektivität	177
7.2.2	Unstrukturierte Ausführungsdaten	178
7.2.3	Prozessergebnis und Erklärung	179
7.2.4	Lesbarkeit von Prozessmodellen	180
7.3	Abgrenzung zu ganzheitlichen Ansätzen	181
8	FAZIT UND AUSBLICK	183
8.1	Zusammenfassung	183
8.2	Schlussfolgerungen	185
8.3	Zukünftige Forschungsthemen	186
	LITERATUR	191
	VOLLSTÄNDIGE LISTE EIGENER PUBLIKATIONEN	215
	ANHANG	219

ABBILDUNGSVERZEICHNIS

1	Sechs Phasen des Prozesslebenszyklus nach [69].	3
2	Fünf grundlegende Modellierungsperspektiven nach [127]. Darstellung angelehnt an [8] und [132].	8
3	Prozessmodell eines niederländischen Krankenhauses zur Behandlung und Diagnose von 2765 PatientInnen durch 619 verschiedene Aktivitäten [2].	11
4	Hierarchische Darstellung der vier Gründe (unterste Ebene) für das Fehlen von Prozessdetails in Prozessmodellen.	13
5	Gleichgewicht zwischen Lesbarkeit (Anforderung 2) und Informationsgehalt (Anforderung 1) von Prozessmodellen durch relevante Prozessdetails.	21
6	Abstrakte Darstellung der drei Phasen des Gesamtkonzepts zur Verbesserung von Prozessmodellen durch relevante Prozessdetails.	21
7	Process Mining-Typen (<i>Discovery, Conformance, Enhancement</i>) nach [2].	30
8	Illustration der Erzeugung einer Sicht auf ein Prozessmodell nach [38]. . .	32
9	Entwickeltes Gesamtkonzept mit drei Phasen zur inkrementellen Erweiterung von Prozessmodellen (PM) durch relevante Prozessdetails nach [81].	38
10	Die drei Phasen des Gesamtkonzepts werden auf verschiedene Iterationen und Schritte (1 bis 5) des Prozesslebenszyklus von [69] abgebildet.	40
11	Formalisierte Darstellung der Verbesserungsphase in Anlehnung an [81]. .	41
12	Detailansichten des Analyse- und Annotationsschritts, publiziert in [81]. Abhängig von der Struktur der Daten müssen die Schritte angepasst werden.	45
13	Darstellung des Merkmalsraums der Daten und Trennung	55
14	Ablauf des Metallspritzgussverfahrens nach [63]. Die einzelnen Schritte sind ins Deutsche übersetzt.	57
15	Manuelle Bestückung einer Platte mit Werkstücken (links), die anschließend in einen Sinterofen eingesetzt wird (rechts) [219].	58
16	BPMN-Modell eines Ausschnitts des Metallspritzgussprozesses.	59
17	Negativ und positiv gelabelte Beispiele zu Szenario 1, aufgenommen mit einer Kamera (links) und synthetisch erzeugt (rechts).	61
18	Synthetisch generierte Bilddaten zu Szenario 2.	62
19	Einordnung verschiedener Fachtermini aus dem Bereich der künstlichen Intelligenz nach [246].	65
20	Von LIME erzeugte lokale Erklärungen einer Vorhersage zu verschiedenen Klassen für ein Eingabebild [223].	69
21	LIME findet eine lokale Trennfunktion (gestrichelte Linie) zweier Klassen (rosa und hellblau) an einem Datenpunkt (dickes rotes Kreuz) durch Verwendung weiterer Datenpunkte in der Nähe (dünne rote Kreuze) [223].	71

22	Teilschritte zur Umsetzung des Analyseschritts für unstrukturierte Bilddaten mit LIME.	72
23	Lokale Erklärungen zu Szenario 1 mit $n_{\text{features}} = 10$, angelehnt an [85]. . .	80
24	Lokale Erklärungen zu Szenario 1 mit $n_{\text{features}} = 4$, angelehnt an [85]. . .	81
25	Lokale Erklärungen zu Szenario 2 mit $n_{\text{features}} = 10$, angelehnt an [85]. . .	82
26	Lokale Erklärungen zu Szenario 2 mit $n_{\text{features}} = 2$, angelehnt an [85]. . .	83
27	Übersicht des KDD-Prozesses, orientiert an [78].	84
28	Teilschritte zur Umsetzung des Analyseschritts mit Association Rule Mining für strukturierte (Bild-)Daten.	91
29	Intuitivität als Unterkonzept der Gebrauchstauglichkeit (links) und verwendete Ebenen des Vorwissens bei intuitiver Benutzung (rechts).	111
30	Studienaufbau mit Materialien aus realen Prozessumgebungen.	118
31	Modell C2 mit Sortieraufgabe und bildgestützter Aufgabenannotation. . .	122
32	Überblick des dreiteiligen Studienablaufs; Messinstrumente sind in dunkelgrauer Farbe hervorgehoben.	123
33	Beispiel einer Ausführung zu Modell A1.	126
34	Verschiedene Aspekte im Kontext präferierter Anleitungsformate (links) und Repräsentationsformate von Aufgabenannotationen bzgl. verschiedener Aufgabenstellungen im direkten Modellvergleich (rechts).	128
35	Deskriptive Statistik der drei Aspekte der Intuitivität in Hinblick auf die Repräsentationsformate der Aufgabenannotationen.	129
36	Durchschnittliche Beurteilungen zur mentalen Anstrengung unter Berücksichtigung des Repräsentationsformats und weiterer Variablen.	130
37	Zufriedenheit der StudienteilnehmerInnen unter gleichzeitiger Betrachtung der Aufgabenstellung und des Repräsentationsformats.	134
38	Grafische Oberfläche zur Erweiterung von BPMN-Modellen mit Media-Annotationen nach [282] am Beispiel des Sinterprozesses.	139
39	Ausschnitt einer unter einem BPMN-Diagramm liegenden XML-Datei. .	140
40	Die Anpassung der Verbesserungsphase für eine neue Domäne erfolgt unter Verwendung von Prozesskenntnissen (gestrichelte Rechtecke).	145
41	Einordnung wichtiger Begriffe zur Modellierung und Ausführung von Aufgaben in die Prozessmanagement- und Robotikdomäne nach [86]. . .	148
42	Taxonomiebaum mit generischen Objekttypen (eckige Knoten) und spezifischen Objekttypen (runde Knoten) nach [86].	151
43	Beispiel generischer Objektlagen ($p_1^{\text{Lage}}, p_2^{\text{Lage}}, p_3^{\text{Lage}}$) oder spezifischer Objektlagen (\hat{p}_1^{Lage}), angelehnt an [86].	152
44	Ausschnitt des Grafikeditors von [224, 226] zur Modellierung von Präzedenzgraphen (links) anhand einer virtuellen Arbeitsumgebung (rechts). . .	154
45	Lösung des Anchoring-Problems durch eine Kostenmatrix M (links) und Ausführung der Roboterskills (rechts) nach [86].	155
46	Anpassung der Verbesserungsphase zur Erweiterung von Roboterprozessmodellen (RPM) um relevante Prozessdetails.	156
47	Verfeinerung des generischen Typs ‚Konduktor‘ durch den spezifischen Typ ‚Basis‘ und den generischen (aber spezifischeren) Typ ‚Widerstand‘ nach [86].	159

48	Beispiele typischer Anwendungsfälle für Leichtbauroboter [86]. Die halbtransparenten Objekte entsprechen Zuständen vor der Aufgabenbearbeitung.	161
49	Beispiele generierter Bilder für Szenario 1 [86].	163
50	Beispiele generierter Bilder für Szenario 2 [86].	164
51	Beispiele lokaler Erklärungen beider Szenarien in der Standardkonfiguration von LIME in Anlehnung an [86].	165
52	Beispiele lokaler Erklärungen beider Szenarien nach der Optimierung [86].	168
53	Erweiterung der Verbesserungsphase zur Optimierung von Prozessmodellen für Menschen (MPM) und Roboter (RPM) im Sinne eines ganzheitlichen Prozessmodells (PM) nach [86].	169

TABELLENVERZEICHNIS

4.1	Gesammelte Beispieldaten aus dem Beschichtungsprozess von Platinen mit EP-Harz.	55
4.2	Zu einem Beispielfeld $g(v)$ erzeugte Einträge. Durch die Permutation der Zuweisung des Bildobjekts zu n möglichen Objekten der Tabelle entstehen $\binom{n}{1} = n$ Einträge.	75
4.3	Analyseergebnisse beider Szenarien zu den Experimenten mit $n_{\text{features}} = 10$	79
4.4	Beispiel für Tabelle T_S nach Strukturierung der Bilder.	91
4.5	Beispiel einer 1-aus- n -Kodierung T_H zu den Daten aus Tabelle 4.4.	91
4.6	Ergebnisse der Association Rule Mining Algorithmen bzgl. aller Validierungskriterien und Varianten zu Szenario 1 nach [82].	99
4.7	Ergebnisse der Association Rule Mining Algorithmen bzgl. aller Validierungskriterien und Varianten zu Szenario 2 nach [82].	102
5.1	Verschiedene Aufgabenstellungen, bestehend aus abstrakten Prozessschrittsbeschreibungen und konkretisierenden Aufgabenannotationen nach [80].	119
5.2	Überblick der neun Prozessmodelle mit eindeutigen Bezeichnungen.	121
5.3	Demografische Daten der StudienteilnehmerInnen.	125
5.4	Abweichende Interpretationen der Aufgabenanweisungen im Durchschnitt.	126
5.5	Ergebnisse der paarweisen Modellvergleiche hinsichtlich der drei Aspekte intuitiver Benutzung, publiziert in [80]: Schätzwerte für den Effekt (E), Standardfehler der Schätzwerte (SE) und Signifikanzniveaus p	132
6.1	Ergebnisse des Globalisierungsschritts beider Szenarien basierend auf den Ergebnissen von LIME mit der Standardkonfiguration (Ausreißer (*) mit einer Häufigkeit von weniger als 3% werden entfernt), angelehnt an [86].	166
7.1	Übersicht und Einordnung verwandter Process Mining-Ansätze: Discovery (D), Enhancement (E) und Ereignisprotokolleextraktion (X).	177

ABKÜRZUNGSVERZEICHNIS

AIS	Agrawal, Imielinski, Swami
BETA	Black Box Explanations through Transparent Approximations
BPMN	Business Process Model and Notation
CAD	Computer-Aided Design
CNN	Convolutional Neural Network
EPC	Event-Driven Process Chains
EP-Harz	Epoxidharz
GAM	Gradient Activation Maps
Grad-CAM	Gradient-Weighted Class Activation Mapping
GUV	Genauigkeit und Vollständigkeit
IOT	Internet of Things
ISO	International Organization for Standardization
KPI	Key Performance Indicator
LIME	Local Interpretable Model-Agnostic Explanations
LMM	Linear Mixed Model
LORE	Local Rule-Based Explanations
LTL	Linear Temporal Logic
LSTM	Long/Short-Term Memory
OMG	Object Management Group
PM	Prozessmodell
RFID	Radio Frequency Identification
RPM	Roboterprozessmodell
SBD	Subject Behaviour Diagrams
SEA	Skala zur Erfassung von subjektiv erlebter Anstrengung
SHAP	Shapley Additive Explanations
QUESTI	Questionnaire for the Subjective Consequences of Intuitive Use
UML	Unified Modeling Language
UML/P	Unified Modeling Language suitable for Programming
VK	Validierungskriterium
XAI	Explainable Artificial Intelligence
XES	Extensible Event Stream
XML	Extensible Markup Language

1 | EINFÜHRUNG UND PROBLEMSTELLUNG

Kleine und mittelständische Unternehmen sowie industrielle Großbetriebe sind täglich mit der Aufgabe konfrontiert, gewinnbringend zur Verwirklichung eines Unternehmensziels beizutragen. Diese Herausforderung gestaltet sich je nach Domäne oder Wirtschaftszweig unterschiedlich. Beispielsweise werden im produzierenden Gewerbe durch die Herstellung von Produkten Gewinne erzielt, während im Logistikbereich der sichere Transport von Waren innerhalb festgelegter Zeitvorgaben im Fokus steht. Ein reibungsloser Ablauf zur Erreichung der Ziele erfordert dabei in allen wirtschaftlichen Unternehmen sowohl eine Strukturierung der Arbeitsschritte als auch ihre ausreichende Dokumentation und die Koordination beteiligter Personen. Sind nicht alle Informationen zum Arbeitsablauf vorhanden und transparent, führt dies zu Fehlern oder Problemen in der Prozesskette. Die Folge sind Qualitätsmängel oder Verzögerungen, die mit Gewinneinbußen verbunden sind. Um den Erfolg eines Prozesses zu gewährleisten und somit die Erreichung der Unternehmensziele sicherzustellen, ist die Unterstützung von geeigneten Verfahren und Systemen entscheidend. Sie müssen in der Lage sein, fehlende aber relevante Informationen in Ablaufplänen zu identifizieren und zu ergänzen. Die vorliegende Arbeit widmet sich der Untersuchung von adäquaten und innovativen Technologien für diese Problemstellung. Es wird ein ganzheitlicher Lösungsansatz entwickelt, mit dem Ablaufpläne in Form von Prozessmodellen durch relevante Prozessdetails verbessert werden.

In diesem einführenden Kapitel werden zunächst grundlegende Terminologien und Ansätze aus dem Prozessmanagement beschrieben (Abschnitt 1.1). Anschließend folgt die Hinführung zur Problemstellung durch eine Auseinandersetzung mit bisherigen Herangehensweisen zur Prozessmodellierung und damit verbundenen Anforderungen (Abschnitt 1.2). Basierend darauf wird die angewendete Forschungsmethodik (Abschnitt 1.3) und der Lösungsbeitrag der Arbeit zur Schließung der identifizierten Forschungslücke vorgestellt (Abschnitt 1.4). Den Abschluss bildet eine Übersicht der verschiedenen Kapitel dieser Dissertation mit einer kurzen Beschreibung deren Inhalte (Abschnitt 1.5).

1.1 PROZESSMANAGEMENT

Arbeitsabläufe oder **Prozesse** beschreiben die Überführung von Input zu Output durch eine Reihe von Aktivitäten [125]. Zusätzlich berücksichtigen unternehmerische Arbeitsabläufe, sog. **Geschäftsprozesse**, explizit betriebswirtschaftliche Aspekte und Organisationen zur Erreichung eines Unternehmensziels [15, 280]. Das **Geschäftsprozessmanagement** (engl. *Business Process Management*) beschreibt dabei die Steuerung verschiedener Faktoren in Geschäftsprozessen und kombiniert Wissen aus den Fachbereichen Informationstechnologie und Management [1]. Ziel ist es, die Effizienz und Effektivität eines Unternehmens dauerhaft zu steigern [276].

In dieser Arbeit wird der allgemeinere Begriff des **Prozessmanagements** verwendet. Damit wird betont, dass nicht ausschließlich Geschäftsprozesse berücksichtigt werden, die üblicherweise mit der Verwaltung von Organisationen auf einem bestimmten Abstraktionsniveau assoziiert werden. Dagegen sollen keine Einschränkungen gelten, sodass sämtliche Arten von Prozessen einbezogen werden. Dazu zählen sowohl technische Prozesse wie zum Beispiel Herstellungsabläufe eines Produkts als auch betriebswirtschaftliche Prozesse, die sich auf kaufmännische Tätigkeiten wie die Bearbeitung von Kundenaufträgen beziehen [94]. Das Prozessmanagement deckt ein breites Spektrum von der Prozessautomatisierung und -analyse bis hin zum Betriebsmanagement und der Arbeitsorganisation ab [4]. Konkreter umfasst der Begriff Prozessmanagement verschiedene Konzepte und Techniken für den Entwurf, die Verwaltung, Konfiguration, Umsetzung und Analyse von Prozessen [280].

1.1.1 PROZESSLEBENSZYKLUS

Der **Prozesslebenszyklus** (engl. *process lifecycle*) bildet die Aufgabenbereiche des Prozessmanagements auf einzelne Phasen ab. Diese werden wiederholt durchlaufen, um Prozesse zu verbessern. In der Literatur finden sich verschiedene Definitionen dieses zyklischen Modells, die unter anderem einzelne Phasen unterschiedlich benennen und differenziert detailliert betrachten. Einer der ersten Zyklen ist 1953 in [64] definiert worden. Dort werden vier Phasen unterschieden: Planen, Umsetzen, Überprüfen, Handeln¹. Dabei dienen die vier Schritte zur Verbesserung eines Prozesses, indem (i) im laufenden Betrieb Mängel und deren Ursachen identifiziert werden (Planen), (ii) Maßnahmen zur Beseitigung dieser Mängel ergriffen werden (Umsetzen), (iii) der Erfolg dieser Maßnahmen gemessen wird (Überprüfen) und (iv) die Nachhaltigkeit des neuen Leistungsniveaus durch Standardisierung sichergestellt wird (Handeln) [16]. Basierend auf dieser Definition

¹Deutsche Übersetzung nach [105] der englischen Begriffe ‚Plan, Do, Act, Check‘.

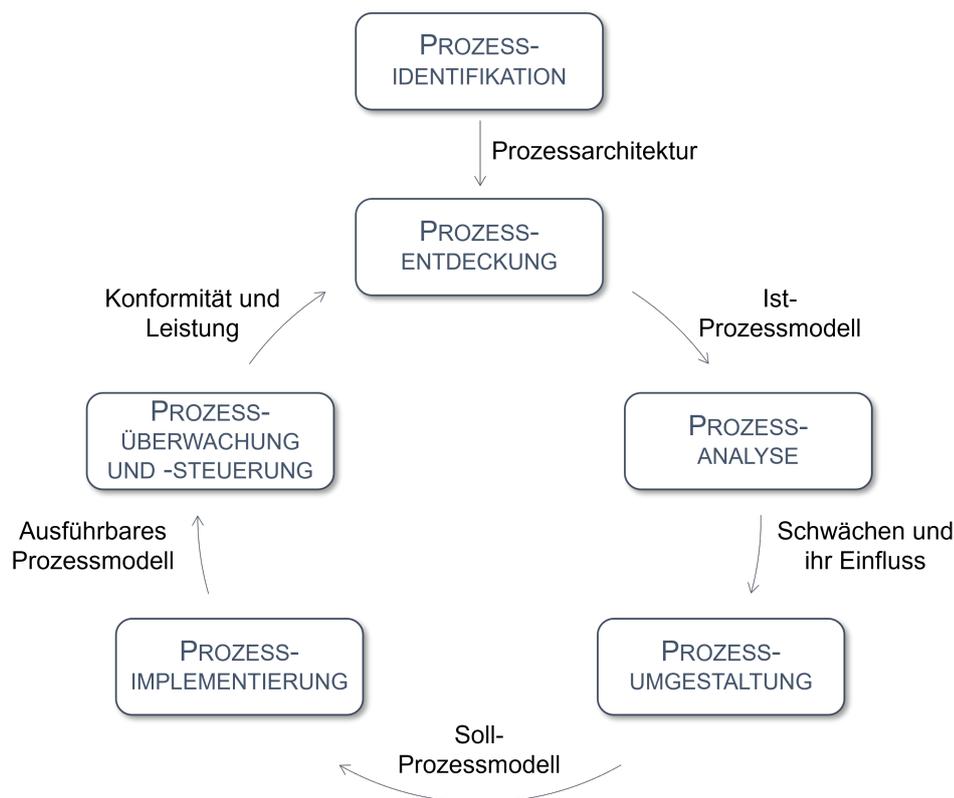


Abbildung 1: Sechs Phasen des Prozesslebenszyklus nach [69].

sind weitere Lebenszyklen entwickelt worden, in denen die Phasen mit unterschiedlichen Schwerpunkten betrachtet werden, aber grundlegend immer enthalten sind [69, 155, 170]. Abbildung 1 zeigt den sechsteiligen Prozesslebenszyklus nach [69].

Die **Prozessidentifikation** (engl. *process identification*) bildet den Einstiegspunkt in das zyklische Modell. In dieser Phase wird zunächst ein Ziel formuliert, das effektiv und effizient erreicht werden soll oder ein betriebliches Problem definiert, das gelöst werden muss. Anschließend werden alle damit verbundenen relevanten Arbeitsabläufe und Schritte ermittelt und eine Prozesslandkarte aufgestellt [98]. Diese gibt einen Überblick über vorhandene Prozesse und ihr Beziehungsgefüge. Daraus wird eine Prozessarchitektur abgeleitet, die formale und inhaltliche Anforderungen festlegt und beschreibt, wie das definierte Ziel mithilfe der Prozesse erreicht werden kann. Durch eine gut gestaltete Prozessarchitektur können Organisationen ein besseres Verständnis für ihre internen Abläufe entwickeln, was für die nachfolgende Phase entscheidend ist.

In der Phase der **Prozessentdeckung** (engl. *process discovery*) (auch: **Prozessdesign**) werden die aktuellen Zustände der Prozesse dokumentiert, die zur Erreichung des vorher definierten Ziels entscheidend sind. Zur Dokumentation kann dabei auf eine Reihe von Prozessmodellierungssprachen zurückgegriffen werden (Abschnitt 1.1.2). Gemäß

den Hauptmerkmalen des allgemeinen Modellbegriffs nach Stachowiak [255] werden die Originalprozesse auf Modelle abgebildet (Abbildungsmerkmal), dabei sinnvolle Abstraktionen vorgenommen (Verkürzungsmerkmal) und die Modelle stellvertretend zum Original für weitere Zwecke verwendet (Pragmatisches Merkmal). Das Ergebnis dieser Phase sind ein oder mehrere Ist-Prozessmodelle, die Momentaufnahmen der aktuellen Abläufe im Unternehmen entsprechen. Für jede Prozessaktivität und allen damit verbundenen AkteurInnen und Objekten wird eine Entität der gewählten Modellierungssprache erstellt. Die Darstellung als Prozessmodell ermöglicht Organisationen nicht nur eine Dokumentation und Strukturierung der Prozesse, sondern auch ein besseres Verständnis für interne Abläufe zu entwickeln. Damit wird die Identifikation potenzieller Engpässe, ineffizienter Schnittstellen oder Optimierungsmöglichkeiten unterstützt.

Anschließend folgt die **Prozessanalyse** (engl. *process analysis*), in der die erstellten Prozessmodelle hinsichtlich ihrer Schwächen und Probleme untersucht werden. Diese werden strukturiert dokumentiert und, wenn möglich, unter Berücksichtigung von Leistungsindikatoren sortiert, z.B. nach der Höhe des Einflusses der identifizierten Schwächen auf den Prozessablauf. In anderen Fällen kann es von Vorteil sein, eine Priorisierung nach dem geschätzten Aufwand vorzunehmen, der erforderlich ist, um den Problemen entgegenzuwirken. Für die Analyse selbst können verschiedene Methoden eingesetzt werden. So können beispielsweise Interviews und Workshops mit den Prozessbeteiligten hilfreich sein, um unzureichende Modellierungen aufzudecken. Auch der Einbezug von ExpertInnenwissen ist von Bedeutung, um Schwachstellen in Modellen zu identifizieren. Dabei ist dieser Aspekt auf die Verfügbarkeit und das vorhandene Wissen beschränkt [166].

In der **Prozessumgestaltung** (engl. *process redesign*) werden die identifizierten Probleme und Schwächen in den Ist-Modellen behoben. Aus diesem Grund wird diese Phase auch als **Prozessverbesserung** bezeichnet. Das vorrangige Bestreben besteht darin, die Prozessmodelle entsprechend anzupassen, um sicherzustellen, dass die Organisation ihre definierten Zielsetzungen effektiver und effizienter erreichen kann. Das Ergebnis dieses Schritts sind Soll-Prozessmodelle, welche sämtliche bis dato bekannten Verbesserungen umfassen und einen optimierten Prozess vorgeben.

In der Phase der **Prozessimplementierung** (engl. *process implementation*) erfolgt anschließend die Umsetzung der Änderungen vom Ist- zum Soll-Zustand des Prozesses, der durch die verbesserten Prozessmodelle vorgegeben wird. Die Prozessimplementierung umfasst dabei zwei Aspekte: Zum einen das organisatorische Änderungsmanagement (engl. *organizational change management*), das sich auf die Aktivitäten bezieht, die erforderlich sind, um die Arbeitsweise aller am Prozess Beteiligten zu ändern. Zum anderen die Prozessautomatisierung (engl. *process automation*), welche die Entwicklung und den Einsatz von IT-Systemen berücksichtigt, um die Umsetzung des Soll-Prozesses

zu unterstützen. Letztere ermöglichen die tatsächliche Ausführung der in den Modellen definierten Aktivitäten durch Prozessausführungssysteme (engl. *business process management system*). Diese umfassen verschiedene Typen von Anwendungssoftware, wie z.B. Systeme zur Planung des Einsatzes von Unternehmensressourcen (engl. *enterprise resource planning system*) oder der Koordination von Arbeitsabläufen (engl. *workflow management system*). Eine Kernfunktion solcher Systeme bildet die Umsetzung von modellierten Aktivitäten in eine Aufgabenliste (engl. *worklist*), die den Prozessteilnehmenden zur Verfügung gestellt wird. Beispielsysteme wie Bizagi [37], Bonita [41] und Camunda [51] verfolgen unter anderem, welche Aktivitäten fällig sind und von wem sie ausgeführt werden. Ergebnis der Prozessimplementierung sind ausführbare Prozessmodelle, die (semi-)automatisch (durch Abbildung in ein Ausführungssystem) oder manuell ausgeführt werden können. Bei der **manuellen** Ausführung werden Prozessmodelle bzw. daraus erstellte Aufgabenlisten von Prozessteilnehmenden gelesen und interpretiert. Anschließend erfolgt die Durchführung der enthaltenen Aufgabenbeschreibungen durch menschliche Interaktionen und händische Tätigkeiten. Ein Beispiel einer solchen Aktivität aus dem Herstellungsbereich ist das Zusammensetzen und Verbinden von Bauteilen. Im Kontext manueller Ausführung werden Prozessmodelle vorwiegend zur Dokumentation, Steuerung und Kommunikation verwendet [237]. Die Prozessimplementierung übernimmt in solchen Fällen ggf. die Aufgabe, die veränderten bzw. neugewonnenen Inhalte im Prozessmodell in eine unternehmensinterne Darstellung zu überführen, um die Ausführung zu erleichtern.

Zuletzt folgt die **Prozessüberwachung und -steuerung** (engl. *process monitoring and controlling*), in der ermittelt wird, wie gut der Prozess hinsichtlich bestimmter Leistungsmerkmale abschneidet. Dafür werden während der Prozessausführung eine Vielzahl verschiedener Daten gesammelt und evaluiert. Außerdem kommen in diesem Schritt Methoden und Techniken zum Einsatz, die Abweichungen vom gewünschten, in den Prozessmodellen definierten Verhalten erkennen und korrigieren.

Anschließend wird der Lebenszyklus erneut durchlaufen, um Veränderungen, neu entdeckte Engpässe oder Probleme im Prozess zu identifizieren und zugrunde liegende Prozessmodelle anzupassen und zu optimieren. Dieser Vorgang ermöglicht eine stetige Verbesserung des gesamten Prozesses und der untergeordneten Teilprozesse.

1.1.2 PROZESSMODELLIERUNG UND PERSPEKTIVEN

Prozesse werden zur Dokumentation und zur unternehmensinternen sowie externen Kommunikation in **Prozessmodellen** (engl. *process models*) abgebildet. Der Bedarf an einer effektiven und vereinheitlichten Sichtbarmachung der Abläufe durch derartige Modelle

ergibt sich aus der mangelnden Übereinstimmung zwischen dem von einer Organisation vorgegebenen Prozess mit dem tatsächlichen Verhalten während des Betriebs. Ursprünglich dienten Beschreibungen von beispielsweise Softwarelebenszyklen zur Dokumentation, die aufgrund ihres unzureichenden Informationsgehalts zu Abweichungen im Prozess führten. Mit der Verwendung derartiger Formate zur Prozessbeschreibung sind vor allem folgende drei problematische Faktoren verbunden [59]:

- (i) Hochgradig präskriptive Prozessbeschreibungen, die keinen Bezug zu den tatsächlichen Projektaktivitäten haben,
- (ii) ungenaue, zweideutige, unverständliche oder unbrauchbare Beschreibungen der in einem Projekt durchzuführenden Prozesse und
- (iii) das Versäumnis, die Dokumentation zu aktualisieren, wenn sich Prozesse ändern.

Die Prozessmodellierung nimmt diese Probleme in Angriff, indem sie ein großes Spektrum an Zielen verfolgt und unterstützt [134]. Dabei unter anderem die Lesbarkeit und Kommunikation, die Verbesserung, das Management und die Ausführbarkeit von Prozessbeschreibungen [59]. Insgesamt ermöglicht die Prozessmodellierung nicht nur eine strukturierte Darstellung der Prozesse, sondern erhöht gleichzeitig die Transparenz der Arbeitsabläufe. Dadurch können Abhängigkeiten identifiziert und Optimierungspotenziale effizient aufgedeckt werden. Aus diesen Gründen ist die Prozessmodellierung heutzutage eine gängige Methode und kommt in verschiedenen Domänen und Unternehmen zum Einsatz. Sie stellt einen essenziellen Bestandteil für die Realisierung der Phasen des Prozessdesigns und der Umgestaltung von Prozessen dar (Abschnitt 1.1.1).

Zur Erstellung von Prozessmodellen haben sich im Laufe der Zeit verschiedene **Prozessmodellierungssprachen** (engl. *process modeling languages*) entwickelt und durchgesetzt. Sie definieren Entitäten mit verschiedener semantischer Bedeutung und legen Regeln fest, wie diese Entitäten miteinander in Beziehung gesetzt werden dürfen. Die spezifische Ausgestaltung von Syntax und Semantik ist abhängig von der gewählten Modellierungssprache. Allgemein wird zwischen natürlichsprachlichen bzw. textuellen und grafischen Sprachen unterschieden.

Zu textuellen Prozessmodellierungssprachen zählen Prozessbeschreibungen im Sinne von informellen Texten in natürlicher Sprache. Daneben existieren aber auch formalisierte natürliche Sprachen, die vor allem zur semantischen Modellierung dienen, wie beispielsweise *Gellish* [273] oder die *Web Ontology Language* [27].

Grafische Prozessmodellierungssprachen ermöglichen die visuelle Darstellung von Arbeitsabläufen und Geschäftsprozessen mittels Symbolen und grafischen Elementen wie

Pfeilen oder Rechtecken. Unter diesen Sprachen ist die *Business Process Model and Notation* (BPMN) eine weit verbreitete und anerkannte Methode. Sie wurde von der *Object Management Group* (OMG) [185] entworfen, einem Konsortium, das Standards für die Modellierung objektorientierter Systeme konzipiert und die Sprache bis heute weiterentwickelt. Unterstützt durch die nachhaltige Förderung der OMG, gilt BPMN seit 2013 mit der Version 2.0.1 als etablierter Standard in der Prozessmodellierung [124]. Sie hat im Gegensatz zu seiner Vorgängerversion eine eindeutig definierte Bedeutung der Symbole und ein natives Serialisierungsformat [54]. Darüber hinaus ermöglicht BPMN sowohl die Abbildung fachlicher als auch technischer Anforderungen und erlaubt die Verbindung textueller Notationen mit grafischen Darstellungen [186]. Daher wird im Kontext dieser Arbeit BPMN zur Prozessmodellierung verwendet. Daneben gibt es weitere grafische Prozessmodellierungssprachen, die für ähnliche Zwecke verwendet werden können, wie z.B. *Unified Modeling Language* (UML) [42], *Event-Driven Process Chains* (EPC) [235] und *Yet Another Workflow Language* [9]. Jedoch sind sie im Vergleich zu BPMN wesentlich weniger verbreitet [110], weshalb sie im Folgenden nicht weiter behandelt werden.

Prozessmodelle müssen verschiedene Informationen enthalten, um einen Ablauf für alle Beteiligten abzubilden. Üblicherweise gehören dazu folgende Aspekte [59, 126]:

- **Was** getan werden soll,
- **wer** es tun soll,
- **wo** und **wann** es getan werden soll,
- **wie** und **warum** es getan werden soll und
- wer davon **abhängig** ist, dass es getan wird.

Die Fragestellungen zielen auf orthogonale Informationen ab, die sich gegenseitig ergänzen und in einem Prozessmodell miteinander verbunden werden. Basierend darauf haben sich fünf Grundperspektiven der Prozessmodellierung (engl. *workflow perspectives*) entwickelt, die in Abbildung 2 zusammengefasst sind [127]:

- **Funktionsperspektive** (engl. *functional perspective*): Die Funktionsperspektive charakterisiert, was in einem Arbeitsablauf getan werden muss und beschreibt somit die Aktivitäten, also die funktionalen Komponenten eines Prozesses. Sie fungiert als Ausgangspunkt, an den die anderen Perspektiven anknüpfen. Zudem bestimmt die Funktionsperspektive die Zerlegung einer Aktivität in kleinere Einheiten und unterscheidet zwischen elementaren Aktivitäten und ihrer Aggregation zu komplexeren Aktivitäten. Letztere werden häufig durch ein hierarchisch strukturiertes Prozessmodell dargestellt,

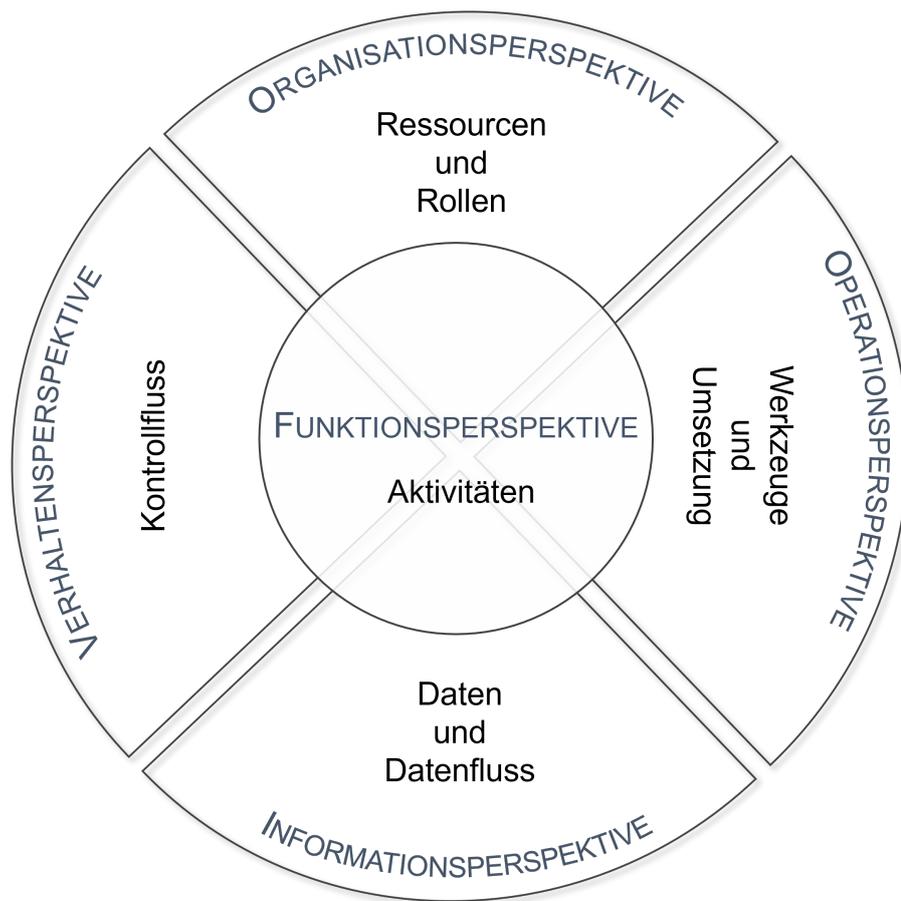


Abbildung 2: Fünf grundlegende Modellierungsperspektiven nach [127]. Darstellung angelehnt an [8] und [132].

in denen elementare Aktivitäten die unterste Ebene bilden. Sie sind logische Arbeitseinheiten, die als Aufgaben (engl. *tasks*) bezeichnet werden und zur Erreichung eines Prozessziels ausgeführt werden müssen.

- **Verhaltensperspektive** (engl. *behavioral perspective*): Die Ausführungsreihenfolge der Aktivitäten wird durch die Verhaltensperspektive beschrieben. Sie kennzeichnet den Kontrollfluss, der den Ablauf und die Steuerung eines Prozesses darstellt. Hierzu werden kausale und temporale Abhängigkeiten zwischen den einzelnen Aktivitäten und Entscheidungspunkten festgelegt. In einem grafischen Prozessmodell wird der Kontrollfluss üblicherweise durch gerichtete Kanten zwischen den Aktivitäten visualisiert.
- **Informationsperspektive** (engl. *information perspective*): Diese Perspektive wird auch als Daten- und Datenflussperspektive bezeichnet [126] und definiert, welche Daten von welcher Aktivität in einem Arbeitsablauf benötigt und erzeugt werden. Sie ordnet somit den einzelnen Aktivitäten Eingabe- und Ausgabeparameter zu und legt die Daten-

abhängigkeit zwischen ihnen fest. Diese ‚Ausgabe-Eingabe-Beziehung‘ zwischen zwei Aktivitäten wird dabei als Datenfluss bezeichnet. Die im Arbeitsablauf verwendeten Daten werden in Produktionsdaten und Kontrolldaten unterschieden. Produktionsdaten sind beispielsweise Dokumente, Formulare oder Tabellen die (physische) Informationen über die hergestellten Produkte und damit verbundene Aspekte umfassen. Während Produktionsdaten losgelöst von administrativen Aufgaben sind und auch ohne formale Definition eines Prozesses existieren, entstehen Kontrolldaten ausschließlich durch Verwendung eines Systems zur Koordination eines Arbeitsablaufs [126]. Sie werden für Verwaltungszwecke eines Prozesses sowie zur Überwachung und Kontrolle von Aktivitäten genutzt. Abhängig vom gewählten Abstraktionslevel kann die Informationsperspektive auch jegliche Art von lokalen Variablen eines Arbeitsablaufs beschreiben, die im Zusammenhang mit Vor- und Nachbedingungen der Aufgabenausführung stehen [9]. Solche Informationen werden als prozessrelevante Daten bezeichnet [220].

- **Organisationsperspektive** (engl. *organizational perspective*): Die Organisationsperspektive erörtert die personellen Zuständigkeiten für die Durchführung einer Aktivität und beantwortet somit die Frage nach der personellen Verantwortlichkeit für einen Prozessschritt. Typischerweise wird die Struktur einer Organisation durch Rollen, Gruppen und andere Artefakte definiert, die organisatorische Aspekte regeln. In einem Prozessmodell werden Aufgaben entsprechenden neutralen organisatorischen Bezeichnungen zugewiesen anstatt konkrete Personen anzugeben [49].
- **Operationsperspektive** (engl. *operational perspective*): Anhand der Operationsperspektive wird die Implementierung eines Prozessschritts beschrieben und definiert, welche Werkzeuge und Systeme zu dessen Durchführung benötigt werden. Das schließt auch elementare Operationen ein, die im Zusammenhang mit der Nutzung dieser Ressourcen stehen und typischerweise dazu führen, dass Daten erzeugt, verändert oder abgerufen werden [8]. Grundsätzlich werden Prozessabläufe häufig unabhängig von deren Implementierung koordiniert. Jedoch wird vorausgesetzt, dass notwendige Ressourcen zur Laufzeit bereitstehen [154].

Die gleichzeitige Betrachtung und Integration aller Perspektiven charakterisiert schließlich den Prozessablauf. Die Erstellung eines Prozessmodells unter Einbeziehung verschiedener Perspektiven ist heutzutage eine etablierte Methode, die in anerkannten Modellierungsansätzen verankert ist [186]. Diese Vorgehensweise repräsentiert ein grundlegendes Modellierungsparadigma und stellt einen relevanten Aspekt in der Forschung dar [132, 171, 216, 237, 292].

1.2 HERAUSFORDERUNGEN IN DER PROZESSMODEL- LIERUNG

Die verschiedenen Prozessperspektiven unterstützen Modellierende dabei, ein möglichst umfassendes Prozessmodell zu erstellen, indem sie orthogonal voneinander betrachtete Informationen zusammenführen. Ihre Berücksichtigung bietet eine solide Grundlage, um alle wesentlichen Aspekte eines Prozesses einzubeziehen. Dennoch bleibt die Abbildung eines realen Prozesses in einem Modell nach wie vor eine große Herausforderung. Schließlich muss ein häufig sehr komplexer Sachverhalt mit einer gewählten Modellierungssprache unter Berücksichtigung von Syntax und Semantik in ein Modell übersetzt werden. Das Ziel besteht dabei immer darin, ein möglichst effektives Modell zu erstellen. Dieses Bestreben und die damit einhergehende Problematik wird in der Literatur ausgiebig diskutiert und von verschiedenen Standpunkten aus beleuchtet [3, 28, 99, 123, 210]. Die damit verbundenen Aspekte werden im nächsten Abschnitt genauer untersucht.

1.2.1 ANFORDERUNGEN AN EFFEKTIVE PROZESSMODELLE

In [59] findet sich eine Zusammenfassung der Zielsetzungen der Prozessmodellierung, aus der sich Anforderungen an ein Prozessmodell ableiten lassen. Ein wesentliches Merkmal der Prozessmodellierung besteht darin, die menschliche Verständigung und Kommunikation zu erleichtern. In diesem Kontext sind insbesondere die folgenden beiden Ziele² für diese Arbeit von besonderer Bedeutung.

1. *Bereitstellung von genügend Information, um einem Individuum oder Team die Ausführung eines definierten Prozesses zu ermöglichen.*

Einerseits müssen ausreichende Informationen in einem Prozessmodell enthalten sein, damit eine Person oder ein Team einen geplanten Prozess effektiv ausführen kann. Die primäre Intention besteht in der Erreichung eines Prozessziels. Die dafür erforderliche Informationsmenge variiert dabei je nach Aufgabenkomplexität.

2. *Darstellung eines Prozesses in einer für Prozessbeteiligte verständlichen Form.*

Andererseits muss ein Prozess in einer Form dargestellt sein, die für Menschen bzw. die Ausführenden gut verständlich und interpretierbar ist. Die Wahl einer geeigneten Modellierungssprache ist hier von besonderer Bedeutung. Zur Beschreibung bestimmter Sachverhalte erweisen sich ausgewählte Sprachen als besser oder weniger geeignet.

²Die Zielbeschreibungen wurden aus [59] ins Deutsche übersetzt.

Modelle müssen stets einen hohen Anspruch an Lesbarkeit erfüllen, sodass der volle Informationsgehalt einem Modell entnommen werden kann.

Diese beiden Punkte sind Anforderungen an Prozessmodelle in Hinblick auf inhaltliche Genauigkeit bzw. Vollständigkeit und Lesbarkeit, die DesignerInnen bei der Modellierung gleichzeitig berücksichtigen müssen. Dabei gilt es zu bedenken, dass beide Aspekte von verschiedenen Charaktereigenschaften abhängen, wie beispielsweise Kompetenz und Erfahrung der Ausführenden bzw. LeserInnen der Prozessmodelle. Dies impliziert, dass diese Dynamik stets als eine ganzheitliche ‚Sender-Empfänger-Beziehung‘ betrachtet werden muss [97]. Modellierende sind folglich damit konfrontiert, auch den Kontext und die Domäne zu berücksichtigen, in dem das Prozessmodell zum Einsatz kommt. Die Vollständigkeit und Verständlichkeit sind gleichermaßen ausschlaggebende Prinzipien für eine erfolgreiche Prozessausführung, wirken jedoch konfligierend.

Ein detailreiches Prozessmodell kann rasch eine hohe Komplexität erreichen und zu großen Modellen führen. [Abbildung 3](#) zeigt ein Beispiel eines unleserlichen Prozessmodells aus dem Gesundheitssektor [2]. Solche Prozessmodelle sind für Ausführende schwer bzw. nicht nachvollziehbar. Die enthaltenen Arbeitsanweisungen sind mit Informationen überladen und dadurch stark verwässert (Konflikt zu Anforderung 2) [3, 38, 203, 251]. Im Gegensatz dazu kann ein abstraktes Modell, bei dem im Interesse der Lesbarkeit Informationsverlust in Kauf genommen wurde, zu generischen Aufgabenbeschreibungen führen. Diese enthalten ungenügend Information, lassen den Ausführenden zu viel Interpretationsspielraum und führen zu unerwünschten Abläufen. Darüber hinaus sind sie im schlimmsten Fall weder nachvollziehbar noch in die Ausführungsumgebung übertragbar (Konflikt zu Anforderung 1) [20, 112, 264].

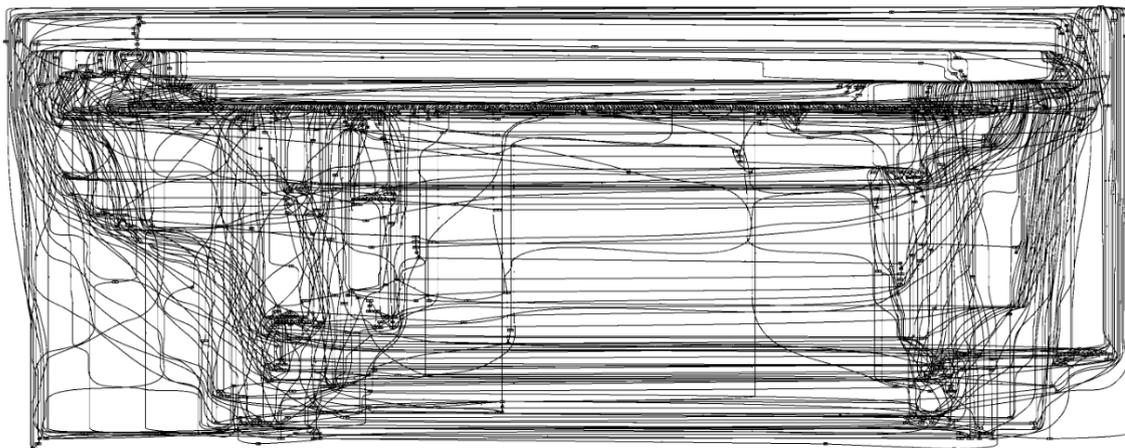


Abbildung 3: Prozessmodell eines niederländischen Krankenhauses zur Behandlung und Diagnose von 2765 PatientInnen durch 619 verschiedene Aktivitäten [2].

Um DesignerInnen bei der Erstellung von Prozessmodellen zu unterstützen, sind eine Reihe von **Prozessmodellierungsleitfäden** (engl. *process modeling guidelines*) entwickelt worden. Diese Leitfäden variieren je nach Modellierungssprache und sind meist auf eine spezifische Sprache zugeschnitten [34, 58, 147, 187]. In [168] sind sieben allgemeine Modellierungsgrundsätze zu finden, die unabhängig von der gewählten Sprache funktionieren und als Orientierungshilfe während der Modellierung dienen können. Jedoch bieten sie, genauso wie andere etablierte Leitfäden, in Bezug auf Entscheidungen zur Detailgenauigkeit eines Prozessmodells nur eine begrenzte Unterstützung. Sie sind zu allgemein gehalten und lassen sich oft aufgrund vieler unsicherer Faktoren und prozessabhängiger Variablen nicht eindeutig anwenden. Darüber hinaus setzt die Anwendung dieser Prinzipien voraus, dass sämtliche Informationen a priori bekannt sind. Wenn dies nicht der Fall ist oder der Fokus zu stark auf der Lesbarkeit eines Modells liegt, entstehen als Folge unvollständige Prozessmodelle, in denen wichtige Details fehlen. Im Kontext dieser Arbeit werden vier Ursachen unvollständiger Prozessmodelle identifiziert, die im Folgenden näher ausgeführt werden.

1.2.2 URSACHEN UNVOLLSTÄNDIGER PROZESSMODELLE

Unvollständige Prozessmodelle enthalten nicht alle notwendigen Informationen, um einen realen Prozess ordnungsgemäß abzubilden. Dabei liegt der Schwerpunkt im Kontext dieser Arbeit auf dem Fehlen sogenannter **Prozessdetails**.

Definition 1 (Prozessdetails). *Prozessdetails entsprechen spezifischen Prozessinformationen, die mit einer Konkretisierung der den fünf Prozessperspektiven zugrunde liegenden Fragestellungen einhergehen.*

Zum Beispiel beantwortet ein Prozessdetail die Frage danach, **wie etwas genau** anstatt lediglich **was** in einem Arbeitsschritt getan werden muss. Der Lösungsraum während der Ausführung wird dadurch näher spezifiziert und eingeschränkt. Grundsätzlich fördert die Berücksichtigung der fünf Perspektiven während der Prozessmodellierung die Erfassung verschiedener Aspekte eines Prozesses und gewährleistet damit ein notwendiges Minimum an Informationen, um einen Prozess insgesamt abzubilden (Abschnitt 1.1.2). Gleichzeitig geben die Perspektiven keine Vorgaben hinsichtlich der Modellierungstiefe. So können abstrakte Modelle entstehen, in denen Prozessinformationen nur grob, vereinfacht oder zusammenfassend modelliert sind. Prozessdetails werden folglich nicht automatisch berücksichtigt und können dabei aus vielen verschiedenen Gründen in Modellen fehlen. Basierend auf Arbeiten im Kontext der Prozessmodellierung sind darunter insbesondere vier Punkte zu identifizieren, die in Abbildung 4 zusammengefasst sind. Diese lassen sich wiederum zwei Gruppen zuordnen, die verschiedene Fälle beschreiben.

Fall 1: Prozessdetails sind (in der Modellierungsphase) grundsätzlich unbekannt.

1. **Fehlendes Prozesswissen:** Nicht immer verfügen Personen, die Prozessmodelle erstellen, über das Fachwissen von ProzessexpertInnen. Folglich besitzen sie kein umfassendes Verständnis sämtlicher Details eines Prozesses. Während die Verantwortung von ProzessdesignerInnen auf der Schaffung eines repräsentativen Prozessmodells liegt, obliegt ProzessexpertInnen die Gewährleistung der inhaltlichen Vollständigkeit eines Modells. Folglich ist ein enger und informativer Austausch zwischen den beiden Rollen eine wichtige Bedingung. Falls dieser nicht optimal funktioniert, werden möglicherweise einige Details unabsichtlich nicht weitergegeben. Eingabeparameter oder implizite Teilaufgaben werden oft als selbstverständlich erachtet, obwohl sie potenziell Einfluss auf das Ergebnis eines Prozesses haben können.

Darüber hinaus kennen selbst ProzessexpertInnen nicht zwangsläufig sämtliche Prozessdetails in vollem Umfang [180], weshalb diese Informationen in solchen Fällen grundsätzlich nicht in einem Prozessmodell berücksichtigt werden können.

2. **Unvorhersehbare Änderungen:** Während der Ausführung eines modellierten Prozesses treten unvorhergesehene Änderungen im Ablauf auf, die während der Entwurfsphase des Modells nicht berücksichtigt werden können [8]. Zum Beispiel erzwingen Systemausfälle Prozessteilnehmende dazu, vom geplanten Arbeitsablauf abzuweichen. Sofern solche Details in zukünftigen Ausführungen berücksichtigt werden sollen, müssen sie identifiziert und in das Prozessmodell integriert werden.

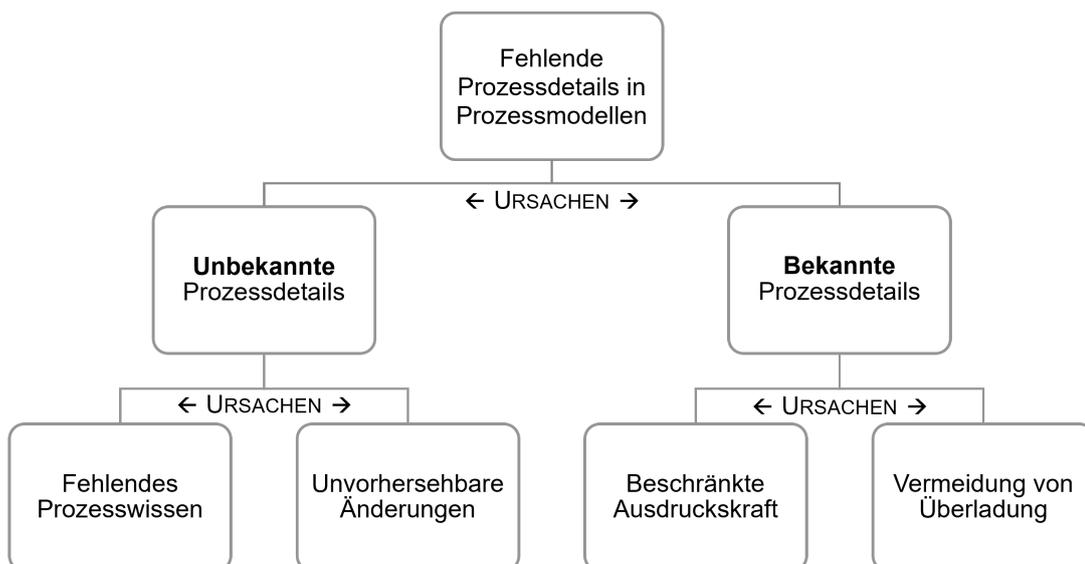


Abbildung 4: Hierarchische Darstellung der vier Gründe (unterste Ebene) für das Fehlen von Prozessdetails in Prozessmodellen.

Fall 2: Prozessdetails sind bekannt, werden aber nicht im Prozessmodell integriert.

3. **Beschränkte Ausdruckskraft:** Gängige Prozessmodellierungssprachen, wie beispielsweise BPMN, sind in ihrer Ausdruckskraft beschränkt. So reichen unter Umständen die bereitgestellten Modellierungselemente einer Sprache nicht aus, um ein bestimmtes Prozessdetail angemessen in ein Modell zu integrieren [194, 282]. In [190] wird erläutert, dass dieser Aspekt auf ein klassisches ‚Henne-Ei-Problem‘ zurückzuführen ist, das die wechselseitige Abhängigkeit zwischen der Bestimmung des Bedarfs an Elementen innerhalb einer Modellierungssprache und dem eigentlichen Akt der Modellierung von Prozessen beschreibt. Um die Elemente einer Modellierungssprache festzulegen, muss Erfahrung im Bereich Prozessmodellierung gesammelt werden; umgekehrt erfordert jedoch die Modellierung von Prozessen bereits das Vorhandensein geeigneter Modellierungselemente.
4. **Vermeidung von Überladung:** Große und komplexe Prozessmodelle sind häufig mit Informationen überladen, wodurch ihre Lesbarkeit stark beeinträchtigt ist. Aus diesem Grund sind verschiedene Abstraktionsmechanismen entwickelt worden [39, 203, 215]. Sie werden auf umfangreiche Modelle angewendet, um die Anzahl der Modellierungselemente und Details zu reduzieren (Abschnitt 2.2.2). Dabei wird bewusst der Verlust von Informationen zugunsten einer Verbesserung der Lesbarkeit und Nachvollziehbarkeit eines Prozessmodells in Kauf genommen. Um bereits in der Designphase große Modelle zu vermeiden, werden selten ausgeführte Teile eines Prozesses von vornherein ausgeschlossen. Beispielsweise wird dieses Vorgehen auf die Modellierung alternativer Pfade im Kontrollfluss angewendet, insbesondere im Kontext der Produktvariantenherstellung. Das Ziel ist dabei nicht nur die Lesbarkeit des Prozessmodells zu erhöhen, sondern auch den Modellierungsaufwand zu reduzieren [113, 226].

1.2.3 RELEVANTE PROZESSDETAILS

Allgemein impliziert die Abbildung eines Sachverhalts, z.B. eines realen Prozesses, in ein Modell zwangsläufig die Notwendigkeit einer Abstraktion und geht so mit einem inhärenten Informationsverlust einher [255]. Allerdings sollte die dadurch verlorene Information redundant sein und somit unerheblich für die erfolgreiche Ausführung eines Prozesses. Ist dies nicht der Fall, ist das ein Indiz für eine fehlerhafte Modellierung eines Prozesses, wodurch wichtige prozessbezogene oder kontextuelle Informationen im Modell fehlen. Unzureichende oder ungenaue Informationen lassen Interpretationsspielräume bei der Ausführung der Aufgabenanweisungen zu, was zu Abweichungen zwischen den einzelnen Ausführungsinstanzen und damit zu Unterschieden in den Prozessergebnissen führen

kann. Auch Verzögerungen oder sogar ein Prozessstillstand sind möglich. In besonders starkem Maße sind Domänen wie die Fertigungsindustrie betroffen, in denen häufig MitarbeiterInnen aus unterschiedlichen Fachrichtungen und ohne betriebsinterne Kenntnisse oder langjährige Erfahrung in der Produktion eingesetzt werden [92]. In solchen Kontexten erweisen sich präzise Anweisungen und umfassende Prozessmodelle als unabdingbar für erfolgreiche Prozessausführungen. Derartige wichtige Prozessinformationen stehen also in Verbindung mit dem Prozess Erfolg und werden basierend auf Definition 1 (Prozessdetails) wie folgt beschrieben.

Definition 2 (Relevante Prozessdetails). *Relevante Prozessdetails sind Prozessdetails, die nachweisbar maßgeblich Einfluss auf den Erfolg eines Prozesses haben.*

Sind relevante Prozessdetails in einem Prozessmodell, beispielsweise aufgrund einer oder mehrerer im vorherigen Abschnitt identifizierten Ursachen, nicht enthalten, können sie während der Ausführung nicht berücksichtigt werden. Dies mindert den Erfolg eines Prozesses und führt im schlimmsten Fall zu einem Prozessfehlschlag. Dabei sind traditionelle Kriterien, an denen der Erfolg eines Prozesses gemessen wird, die Ausführungsdauer, die Prozesskosten und die Qualität des Ergebnisses [55]. Um potenzielle wirtschaftliche Schäden zu verhindern, ist die Integration relevanter Prozessdetails in ein Modell essenziell. Diese werden dabei in verschiedene Typen unterteilt, die auf den fünf Prozessperspektiven aus Abschnitt 1.1.2 basieren. Sie präzisieren die dazugehörigen Betrachtungswinkel und bringen die Ausführung und den Erfolg eines Prozesses mit der Modellierung in Verbindung.

- **Funktionale relevante Prozessdetails:** Ist eine Aufgabenbeschreibung nicht detailliert genug modelliert, fehlen funktionale Prozessdetails. Das bedeutet, dass eine Aufgabe in Teilschritte zerlegbar ist, deren explizite Modellierung für eine korrekte Prozessausführung von Bedeutung ist. Beispielsweise kann die Aufgabenanweisung ‚ein Bauteil bekleben‘ implizite Vor- und Nachbearbeitungsschritte wie ‚Reinigung der Oberfläche‘ oder ‚Andrücken des Klebers‘ beinhalten, die für die Qualität des Endprodukts entscheidend sind. Sind diese nicht als Teilschritte modelliert, werden sie während der Ausführung nicht bzw. nicht zwangsläufig berücksichtigt, was zu abweichenden Prozessergebnissen führt.
- **Verhaltensorientierte relevante Prozessdetails:** Derartige Details beschreiben die explizite Modellierung der Ausführungsreihenfolge von Aufgaben. Fehlen verhaltensorientierte Prozessdetails kann dem Prozessmodell nicht entnommen werden, ob und welche Abhängigkeiten zwischen einzelnen Schritten existieren. So ist zum Beispiel in

einem chemischen Prozess nicht angegeben, in welcher Reihenfolge verschiedene Substanzen miteinander vermischt werden müssen, um eine bestimmte Tinktur herzustellen. Infolgedessen kann es bei bestimmten Kombinationen zu Schaumbildung kommen, was wiederum zu Verzögerungen im Prozess führt.

- **Datenorientierte relevante Prozessdetails:** (Eingabe-)Spezifikationen, Variablen oder Parameter zu einer Aufgabe werden als datenorientierte Prozessdetails definiert. Sie beziehen sich auf Daten bzw. Objekte, die im Kontext einer Aufgabe verwendet werden und die Tätigkeit mit diesen konkretisieren sowie den Handlungs- und Lösungsraum eingrenzen. Sind diese nicht modelliert, fehlt beispielsweise in der Anweisung einer Platzierungsaufgabe die Information, wohin genau die zu platzierenden Objekte auf der Arbeitsfläche positioniert werden sollen. Dabei können die Objektpositionen Einfluss auf eine effektive Ausführung des nachfolgenden Schritts und damit auf den Gesamtprozess haben (z.B. bei der Bereitstellung von Materialien für die Montagelinie).
- **Organisatorische relevante Prozessdetails:** Solche Prozessinformationen beschreiben die Zuordnung von Aufgaben zu AkteurInnen. Meist sind Zuweisungen von Aufgaben zu übergeordneten Rollen (z.B. MitarbeiterIn) gegeben, während Zuordnungen zu konkreten Funktionen und somit speziellen Rollen (z.B. TeamleiterIn) fehlen. Allerdings können diese für eine erfolgreiche Ausführung von Bedeutung sein können. Zum Beispiel kann es sich positiv auf die Effizienz und Effektivität des Gesamtprozesses auswirken, wenn bestimmte Mitarbeitende einer speziellen Rolle eine Aufgabe besonders sorgfältig ausführen. An der Stelle ist anzumerken, dass Prozessmodelle üblicherweise keine konkreten Personen, sondern stets Rollen im Unternehmen enthalten, die an Arbeitsplätze geknüpft sind. Darüber hinaus sind in Modellierungssprachen wie BPMN außerdem nur ‚Eins-zu-eins-Beziehungen‘ zwischen Aufgaben und Rollen zugelassen.
- **Operationale relevante Prozessdetails:** Mangelt es in einem Prozessmodell an näheren Beschreibungen zu Werkzeugen oder Systemen, die in einer Aufgabe verwendet werden, fehlen operationale Prozessdetails. Dies kann beispielsweise die Information sein, dass ein bestimmtes Arbeitsmittel bei der Ausführung einer Aufgabe oder unter einer bestimmten Bedingung einem anderen vorzuziehen ist. Ein konkretes Beispiel findet sich in der Oberflächenbearbeitung, in der eine bestimmte Körnung des Schleifpapiers unter Berücksichtigung der Oberflächenbeschaffenheit und dem angestrebten Aufgabenziel gegenüber einer anderen Körnung zu bevorzugen ist. Fehlende Angaben zur Körnung können zu einer Beeinträchtigung des Prozessergebnisses führen.

Das Fehlen relevanter Prozessdetails des gleichen oder unterschiedlichen Typs im Modell führt zu vermindertem Prozesserverfolg. Die Integration dieser Prozessdetails ist daher

von entscheidender Bedeutung, jedoch aus verschiedenen Gründen nicht trivial umsetzbar oder möglich (Abschnitt 1.2.2). Insbesondere in Situationen, in denen relevante Prozessdetails und damit die Kausalität zwischen Modellierung und Prozesserfolg unbekannt ist, stellt die Identifikation dieser fehlenden Informationen eine erhebliche Herausforderung dar. Darüber hinaus ist es essenziell, sowohl die Anforderungen an die Lesbarkeit als auch an den Informationsgehalt bei der Modellierung von Prozessen gleichzeitig zu erfüllen (Abschnitt 1.2.1). Nur durch die Beachtung dieser beiden Aspekte können Prozessmodelle effizient und effektiv im betrieblichen Umfeld eines Unternehmens genutzt werden. Aus diesen Problemstellungen ergibt sich eine noch offene Forschungslücke, zu der im Folgenden Forschungsfragen formuliert werden. Diese werden im Kontext der vorliegenden Arbeit untersucht und beantwortet.

1.3 FORSCHUNGSMETHODIK

Die Inhalte dieser Arbeit werden gemäß der grundlegenden Forschungsmethodik **Design Science** [114] erarbeitet. Im Design Science-Paradigma werden Wissen und Verständnis eines Problembereichs und dessen Lösung durch die Konstruktion und Anwendung eines abstrakten Objekts erreicht. Das vorrangige Ziel dieser Arbeit besteht in der Beantwortung einer zentralen Forschungsfrage, die wie folgt formuliert ist.

ZENTRALE FORSCHUNGSFRAGE

Wie können Prozessmodelle durch relevante Prozessdetails verbessert werden?

Hierzu bedarf es der Untersuchung von zwei Aspekten, die in Form von untergeordneten Forschungsfragen formuliert sind.

FORSCHUNGSFRAGE 1

Wie können relevante Prozessdetails identifiziert und analysiert werden?

Diese Forschungsfrage umfasst drei Untersuchungsansätze:

- 1.1 Wie kann entdeckt werden, dass Prozessdetails in einem Prozessmodell fehlen?
- 1.2 Wie können relevante von irrelevanten Prozessdetails unterschieden werden?
- 1.3 Welche Typen relevanter Prozessdetails können analysiert werden?

FORSCHUNGSFRAGE 2

Wie können relevante Prozessdetails passend in Prozessmodelle integriert werden?

Auch diese Forschungsfrage lässt sich in drei Teilfragen zerlegen, die zur Erreichung einer umfassenden Antwort beitragen:

- 2.1 Wie müssen analysierte relevante Prozessdetails (nach-)verarbeitet werden, um sie verwenden zu können?
- 2.2 Wie können relevante Prozessdetails für ProzessteilnehmerInnen intuitiv verständlich dargestellt werden?
- 2.3 Wie können bereits existierende Prozessmodelle um relevante Prozessdetails ergänzt werden?

Im Kontext der Design Science-Methode werden sieben Leitlinien festgelegt, um Forschende bei der Beantwortung von Forschungsfragen zu unterstützen und im Problemlösungsprozess zu helfen. In dieser Arbeit wird diesen Leitlinien gefolgt, um die beiden untergeordneten Forschungsfragen zu beantworten und somit zur Lösung der zentralen Forschungsfrage beizutragen. Im Folgenden werden die Leitlinien skizziert und es wird erläutert, wie sie im vorliegenden Forschungsthema umgesetzt wurden.

1. **Design als Artefakt** (engl. *design as an artifact*). Forschung, die der Design Science folgt, benötigt die Erzeugung eines innovativen, zweckmäßigen Artefakts, wie beispielsweise Software, Methoden, Modelle oder Konzepte. In dieser Arbeit entstehen drei Arten von Artefakten: (i) Ein Gesamtkonzept zur Identifikation und Analyse noch unentdeckter, relevanter Prozessdetails (Kapitel 3), (ii) prototypische Implementierungen zur Umsetzung und Evaluation des Konzepts (Kapitel 4), und (iii) eine empirische Methode zur Untersuchung der intuitiven Benutzbarkeit verschiedener Darstellungsmöglichkeiten von Prozessdetails (Kapitel 5).
2. **Problemrelevanz** (engl. *problem relevance*). Das Ziel besteht darin, technologiebasierte Lösungen für wichtige und relevante Probleme in einer definierten Domäne zu entwickeln. Der Schwerpunkt des Problembereichs liegt in dieser Arbeit auf der Prozessmodellierungsdomäne und dort konkreter auf relevanten Prozessdetails. Der Ausschluss dieser Details in einem Modell führt zu reduziertem Prozesserfolg und Verlusten für Unternehmen (Abschnitt 1.2.3).
3. **Evaluation des Designs** (engl. *design evaluation*). Die Evaluierungsmethoden müssen sorgfältig angewendet werden, um den Nutzen, die Qualität und die Effektivität eines

Artefakts zu beurteilen. Mithilfe von kontrollierten Experimenten, die realen Szenario-beschreibungen folgen, wird die Anwendbarkeit des entwickelten Verfahrens gezeigt (Abschnitte 4.3.2 und 5.2.2). Implementierungen werden mit funktionalen Tests und gesammelten (Studien-)Daten, u.a. durch Verwendung statistischer Methoden, standardgemäß und transparent evaluiert (Abschnitte 4.4.5, 4.5.5, 5.3.2 und 6.4).

4. **Forschungsbeiträge** (engl. *research contributions*). Die erarbeiteten Artefakte, Grundlagen und Methoden müssen einen klaren und überprüfbaren Beitrag im jeweiligen Forschungskontext leisten. Unter Berücksichtigung der beiden in Abschnitt 1.2.1 hervorgehobenen Anforderungen an Prozessmodelle, werden eine zentrale Forschungsfrage sowie zwei untergeordnete Forschungsfragen formuliert. Deren Beantwortung stellt einen Beitrag zur Forschung in der Prozessmodellierungsdomäne dar.
5. **Wissenschaftliche Stringenz** (engl. *research rigor*). Forschung, die dem Ansatz der Design Science folgt, stützt sich auf die Anwendung strenger Methoden sowohl bei der Konstruktion als auch bei der Bewertung von Artefakten. Jedes Kapitel der vorliegenden Arbeit orientiert sich an diesem Leitsatz. Das entwickelte Gesamtkonzept und seine Umsetzung sind sorgfältig beschrieben und formal definiert. Nachweise zu anderen Ansätzen, auf denen die Arbeit basiert oder die in dieser Arbeit verwendet werden, sind transparent angegeben und nachvollziehbar begründet. Zur Sicherstellung der Reproduzierbarkeit der Forschungsergebnisse sind alle gewählten Methoden, Algorithmen und Experimente ausführlich dokumentiert.
6. **Design als Suchprozess** (engl. *design as a search process*). Die Artefaktkonstruktion beinhaltet einen Suchprozess, bei dem ein Problemraum aufgespannt wird. Dabei wird ein Mechanismus entwickelt oder aktiviert, um eine effektive Lösung zu finden. Dieser Mechanismus kann selbst Teil des entstehenden Artefakts sein. Der Problemraum wird im Kontext dieser Arbeit durch eine gründliche Recherche nach bestehenden Methoden und Ansätzen definiert. Die dadurch mögliche Identifikation der Forschungslücke bzgl. relevanter Prozessdetails wird mit der Abgrenzung zu existierenden Ansätzen verdeutlicht (Kapitel 7).
7. **Kommunikation der Forschung** (engl. *communication of research*). Die Forschungsergebnisse müssen mit einem heterogenen Publikum kommuniziert werden, darunter sowohl mit einem technischen (z.B. andere Forschende aus dem Fachbereich) als auch mit einem unternehmerischen Publikum (z.B. Entscheidungstragende zur Umsetzung

der Forschungsinhalte in ihren Organisationen). Die Forschungsergebnisse dieser Arbeit sind in mehreren Publikationen veröffentlicht und auf internationalen Fachkonferenzen präsentiert worden. Eine vollständige Liste themenbezogener Publikationen ist am Ende der Arbeit zu finden (,Thematisch relevante Publikationen‘ im Anhang).

Die Design Science beschreibt ein weitverbreitetes Forschungsparadigma, das ursprünglich im Kontext von Informationssystemen entstanden ist. In Kombination mit der Methodik der verhaltenswissenschaftlichen Forschung **Behavioral Science** [114], die darauf ausgerichtet ist, organisatorische Fähigkeiten durch die Entwicklung innovativer Artefakte zu erweitern, fungiert dieses Konzept als Schnittstelle zwischen Individuen, Organisationen und Technologie. Die beiden Paradigmen sind für die Disziplin ,Informationssysteme‘ von grundlegender Bedeutung und sind in den vergangenen Jahren aus verschiedenen Blickwinkeln ergänzt worden. Beispielsweise sind Aspekte innerhalb der Forschungsmethode der Design Science identifiziert worden, die ausschlaggebend für die Übertragung des Konzepts in andere Bereiche sind [164]. Andere Arbeiten unterstützen die Operationalisierung des Paradigmas und beziehen die Entwicklung von Systemen durch Experimente und Beobachtungen ein [197].

1.4 LÖSUNGSANSATZ UND BEITRAG

Im Folgenden wird ein Überblick über die im Rahmen dieser Arbeit entwickelten Methoden zur Beantwortung der Forschungsfragen gegeben. Dabei besteht das grundlegende Ziel darin, eine Lösung für die in Abschnitt 1.2.1 beschriebenen Anforderungen an Prozessmodelle zu entwickeln. Die gleichzeitige Erfüllung beider Anforderungen erweist sich als komplex, da die Berücksichtigung der einen Anforderung zu Einschränkungen in der Umsetzung der anderen führt. So steht eine stark detaillierte Modellierung und informationsreiche Abbildung eines Prozesses im Konflikt mit der Übersichtlichkeit und Lesbarkeit eines Prozessmodells. Abbildung 5 skizziert, wie relevante Prozessdetails diesen Konflikt auflösen. Prozesse werden mit möglichst geringer Komplexität modelliert wodurch abstrakte, aber gut verständliche Prozessmodelle entstehen. Diese werden anschließend mit relevanten Prozessdetails angereichert. Durch dieses Vorgehen bleibt die Lesbarkeit eines Modells erhalten, ohne den für Prozessenerfolg erforderlichen Informationsgehalt zu vernachlässigen. Prozessmodelle mit redundanten Prozessinformationen, die aus einer zu detaillierten Modellierung resultierenden, werden verhindert. Dagegen entstehen möglichst einfache Prozessmodelle, die ausschließlich essenzielle Informationen enthalten. Die Berücksichtigung relevanter Prozessdetails in Modellen löst dabei nicht nur das Problem der Wahl eines passenden Abstraktionsgrads in der Modellierungsphase,

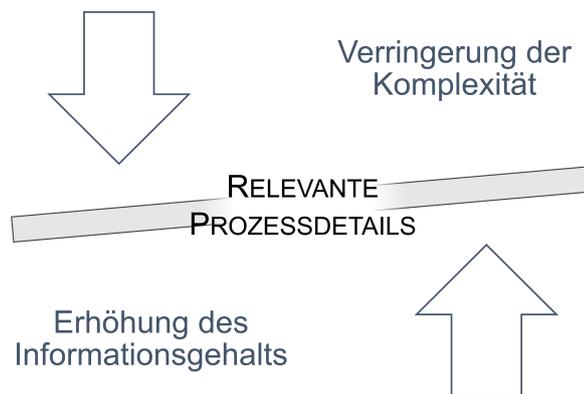


Abbildung 5: Gleichgewicht zwischen Lesbarkeit (**Anforderung 2**) und Informationsgehalt (**Anforderung 1**) von Prozessmodellen durch relevante Prozessdetails.

sondern ermöglicht auch die Erweiterung eines Prozessmodells um bisher unentdecktes Prozesswissen. Die Verbesserung von Prozessmodellen durch die Einbeziehung relevanter Details erfordert mehrere Schritte, welche im Rahmen dieser Arbeit entwickelt, ausgearbeitet und in ein Gesamtkonzept eingebunden werden. Das Gesamtkonzept beschreibt einen iterativen Prozess, in dem pro Durchlauf zunächst fehlende Prozessdetails identifiziert und anschließend im Prozessmodell ergänzt werden. Insgesamt werden dabei drei Phasen unterschieden, die in **Abbildung 6** vereinfacht illustriert sind. In der Beobachtungsphase wird das Fehlen relevanter Prozessdetails festgestellt. In der Verbesserungsphase werden diese Details identifiziert und im Modell ergänzt. In der Validierungsphase erfolgt eine Prüfung des dadurch erweiterten Prozessmodells und ggf. ein erneuter Anstoß der Verbesserungsphase. Das Gesamtkonzept sowie die einzelnen Phasen werden ausführlich in **Kapitel 3** erläutert.

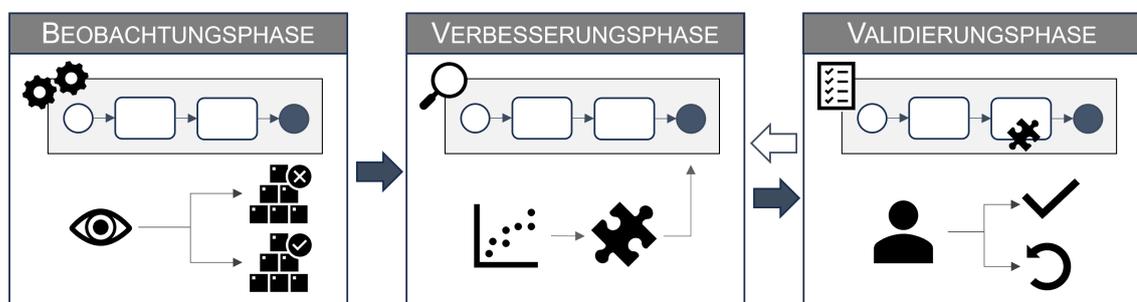


Abbildung 6: Abstrakte Darstellung der drei Phasen des Gesamtkonzepts zur Verbesserung von Prozessmodellen durch relevante Prozessdetails.

1.4.1 ANALYSE RELEVANTER PROZESSDETAILS

Ein integraler Bestandteil der Verbesserungsphase ist der Analyseschritt. In diesem werden relevante Prozessdetails identifiziert und extrahiert (**Forschungsfrage 1**). Dafür werden die während der Prozessausführung gesammelten Daten mit entsprechenden Verfahren analysiert (Kapitel 4). In dieser Arbeit wird die konkrete Umsetzung des Analyseschritts am Beispiel der Extraktion datenorientierter relevanter Prozessdetails aus Bilddaten gezeigt. Hierbei werden verschiedene Verfahren aus dem Bereich des maschinellen Lernens verwendet. Zur Verarbeitung unstrukturierter Daten wird ein Ansatz aus der **erklärbaren künstlichen Intelligenz** (engl. *Explainable Artificial Intelligence* (XAI)) eingesetzt, während für strukturierte Daten eine regelbasierte Methode aus dem Bereich **Data Mining**³ genutzt wird. Dabei übernehmen beide Ansätze die Aufgabe, auf Grundlage von Abweichungen in den Prozessausführungen den Zusammenhang bestimmter Aktivitäten mit Prozesserverfolg zu erklären. Sie sind damit in gewisser Weise als Fehlerursachenanalyse zu betrachten, gehen jedoch einen Schritt weiter und liefern durch die Bestimmung relevanter Prozessdetails konkret die Informationen, die zur Erhöhung des Prozesserverfolgs in zukünftigen Ausführungen beachtet werden müssen. Die Extraktion solcher Informationen zur Anreicherung von Prozessmodellen repräsentiert eine innovative Methode in einem noch unbearbeitetem Forschungsfeld. Im Rahmen der Arbeit werden die Ansätze in prototypischen Implementierungen umgesetzt und anschließend in Experimenten umfassend evaluiert.

1.4.2 INTEGRATION RELEVANTER DETAILS IN PROZESSMODELLE

Die Rückführung analysierter Prozessdetails in ein existierendes Prozessmodell ist ein weiterer Kernschritt der Verbesserungsphase. Er stellt eine eigenständige Herausforderung dar und wird in dieser Arbeit genauer betrachtet (**Forschungsfrage 2**). In diesem Kontext erfolgt eine Unterscheidung zwischen zwei wesentlichen Aspekten: der repräsentativen und der technischen Integration. Die repräsentative Integration bezieht sich auf die Art und Weise, wie Prozessdetails in einem Modell dargestellt werden. Die technische Integration hingegen befasst sich mit der Erweiterung eines bestehenden Modells durch zusätzliche Informationen und adressiert grundsätzliche Ergänzungsmethoden. Dabei können, abhängig davon, wie ein relevantes Prozessdetail im Modell dargestellt werden soll, bestimmte Anforderungen an die technische Integration entstehen. Zusätzlich kann es erforderlich sein das Prozessdetail nachzubearbeiten (z.B. in eine bestimmte Struktur zu bringen), um es (automatisch) in eine gewünschte Darstellung zu überführen. Kapitel 5

³ ‚Data Mining‘ ist ein feststehender Begriff in der Wissenschaft und wird in dieser Arbeit mit seinem englischen Terminus verwendet.

widmet sich einer ausführlichen Diskussion dieser Aspekte, wobei der Schwerpunkt auf der adäquaten Darstellung relevanter Prozessdetails in Modellen liegt. Die in einem Prozessmodell beschriebenen Arbeitsanweisungen müssen für Menschen verständlich sein, um eine erfolgreiche Ausführung zu ermöglichen. Idealerweise können sie intuitiv ohne Anstrengung korrekt interpretiert werden. Diese Anforderungen gelten gleichermaßen für die Darstellung relevanter Prozessdetails. Die Untersuchung dieses Aspekts erfolgt im Rahmen einer eigenständig konzipierten und durchgeführten experimentellen Nutzerstudie. Verschiedene Repräsentationsformate relevanter Prozessdetails werden in Form von **Aufgabenannotationen** im Zusammenhang mit der Tätigkeit bzw. Aufgabenstellung evaluiert. Die Ergebnisse geben Aufschluss darüber, wie relevante Prozessinformationen intuitiv in einem Prozessmodell dargestellt werden können. Diese Erkenntnisse leisten nicht nur einen signifikanten Beitrag zur Realisierung des Gesamtkonzepts, sondern sind umfassend auf analoge Herausforderungen in der Prozessmodellierung übertragbar. Die Studie schließt eine vorhandene Forschungslücke, da bisherige Studien in diesem Kontext weder inhaltlich, noch konzeptionell diesen Aspekt untersuchen.

1.4.3 ÜBERTRAGBARKEIT IN VERSCHIEDENE DOMÄNEN

Eine weitere Stärke des entwickelten Gesamtkonzepts manifestiert sich in seiner abstrakten Architektur und modularen Gestaltung. Die einzelnen Bestandteile können je nach Anwendungsfall implementiert und angepasst werden. Die Bereitstellung einer solch adaptierbaren Architektur ist Voraussetzung für die praktische Anwendung in verschiedenen realen Prozessumgebungen. Dabei werden in dieser Arbeit Experimente zu den Kernschritten des Gesamtkonzepts anhand von Beispielen aus der Fertigungsdomäne durchgeführt. Allerdings kann das entwickelte Verfahren auch für die Verbesserung von Abläufen und Prozessmodellen in weiteren Arbeitsbereichen eingesetzt werden. Seine Übertragbarkeit auf verschiedene Prozesse in unterschiedlichen Domänen wird ausführlich diskutiert und effektiv am Beispiel der Robotik demonstriert (Kapitel 6). Die Modularität des Gesamtkonzepts ermöglicht eine gewisse Flexibilität und damit eine kontinuierliche Erweiterung der gewählten Techniken oder den Austausch durch alternative Methoden.

Eine entscheidende Charakteristik des entwickelten Gesamtkonzepts liegt in seiner extrinsischen Herangehensweise zur Prozessmodellverbesserung. Extrinsische Ansätze ziehen Daten aus verschiedenen externen Datenquellen in der Prozessumgebung heran, um Optimierungspotenziale zu ermitteln. Im Gegensatz zu intrinsischen Verbesserungsansätzen, die lediglich bekannte und im Modell abgebildete Prozessinformationen betrachten, ist dieses Vorgehen unerlässlich, um noch unbekanntes aber relevante Prozessinformationen zu analysieren. Darüber hinaus werden im entwickelten Gesamtkonzept

innovativ verschiedene Aspekte gleichzeitig betrachtet. Es werden diverse Prozessperspektiven (Multiperspektivität), unterschiedliche Datenquellen und -strukturen, Ursachen in Bezug auf den Erfolg von Prozessen und die Bewahrung der Lesbarkeit von Prozessmodellen untersucht. Diese Dimensionen werden in existierenden extrinsischen Ansätzen entweder nur einzeln oder im Sinne von Teilmengen gleichzeitig betrachtet. Eine umfassende Erläuterung bestehender Arbeiten in diesem Kontext sowie eine Abgrenzung zum entwickelten Gesamtkonzept und verwendeter Methoden finden sich in Kapitel 7. Innerhalb der beiden Kapitel zum Analyse- und Annotationsschritt (Kapitel 4 und 5) werden außerdem Grundlagen und Techniken erläutert, auf denen die Methoden aufbauen. An dieser Stelle werden kurz die wichtigsten Unterschiede zu bisherigen extrinsischen Herangehensweisen zusammengefasst. Ein Großteil verwandter Ansätze, die sich mit der Extraktion von unbekanntem Prozesswissen aus Ausführungsdaten beschäftigen, verwenden strukturierte Datenbestände. Dabei stammen diese Daten typischerweise aus Ausführungssystemen, wodurch der Informationsgehalt von vornherein beschränkt und das Datenschema vordefiniert ist. In den meisten Fällen beziehen sich die enthaltenen Informationen auf die funktionale und verhaltensorientierte Perspektive, weshalb nur Aktivitäten und der Kontrollfluss eines Prozesses betrachtet werden. Zwar gibt es darunter Verfahren, welche sich mit der Gewinnung von Informationen aus weiteren Datenquellen auseinandersetzen, jedoch bezieht keine dieser Methoden den Prozessenerfolg mit ein. Diese Dimension ist allerdings essenziell, um darunter relevante Prozessinformationen zu identifizieren. Ansätze, die den Prozessenerfolg zur Untersuchung von Ursachen eines Fehlschlags untersuchen, erweitern Prozessmodelle wiederum nicht nachhaltig um diese Information. Sie werden typischerweise eher zur Kontrolle des Ablaufs eingesetzt und dienen zur Unterstützung von Entscheidungsfindungen während der Prozessausführung. Außerdem ist die Betrachtung verschiedener Datenquellen nicht vorgesehen.

Abschließend ist hervorzuheben, dass das Ziel dieser Dissertation die Ausarbeitung eines Lösungsansatzes zur Beantwortung der zentralen Forschungsfrage ist. Dafür werden verschiedene Forschungsrichtungen aus den Bereichen Prozessmanagement, Data Mining, Bildverarbeitung, künstlicher Intelligenz, Robotik und empirische Sozialforschung im Rahmen der Entwicklung und Anwendung des Gesamtkonzepts miteinander verbunden sowie eine Leitlinie für weiterführende Forschungsaktivitäten etabliert. Der Beitrag des Konzepts hängt dabei maßgeblich von der Effektivität der Analyse und Integration relevanter Prozessdetails ab. Daher fokussiert sich diese Arbeit auf die Entwicklung geeigneter Methoden, um die Umsetzbarkeit dieser Schritte zu demonstrieren und ihre Eignung im Kontext realer Anwendungen zu evaluieren.

1.5 AUFBAU DER ARBEIT

Die vorliegende Arbeit umfasst insgesamt acht Kapitel, deren Inhalte im Folgenden kurz zusammengefasst sind.

In Kapitel 1 erfolgt eine Einführung in das Gebiet des Prozessmanagements sowie in die zentralen Herausforderungen der Prozessmodellierung. Die zugrunde liegenden Problemstellungen werden verdeutlicht und ein umfassender wissenschaftlicher Lösungsansatz zur Bearbeitung der noch offenen Forschungslücke skizziert.

Kapitel 2 gibt einen Überblick über verschiedene etablierte Optimierungsansätze für Prozessmodelle aus der Fachliteratur. Darunter wird zwischen inhaltlichen Verbesserungen von Prozessmodellen und Optimierungen zugunsten der Lesbarkeit unterschieden.

In Kapitel 3 wird das entwickelte Gesamtkonzept zur Verbesserung von Prozessmodellen durch relevante Prozessdetails beschrieben. Verschiedene Aspekte zur Herangehensweise und die einzelnen Schritte des Konzepts werden detailliert erläutert.

Kapitel 4 befasst sich mit der praktischen Umsetzung des Analyseschritts gemäß dem im Gesamtkonzept skizzierten Ansatz. Hierbei konzentriert sich die Arbeit auf die Identifikation relevanter Prozessdetails in Bilddaten, wobei die Eignung dieser Datenquelle für die Erfassung solcher Details ausführlich diskutiert wird. Für die Umsetzung werden verschiedene Methoden aus dem Bereich des maschinellen Lernens vorgestellt, die sich zur Extraktion relevanter Prozessdetails eignen. Diese Methoden werden im Detail erörtert, prototypisch implementiert und anschließend evaluiert. Hierfür wird ein spezieller Experimentaufbau entworfen, der sich an einem realen Beispielprozess im Bereich des Metallspritzgusses orientiert und den Schwerpunkt auf die Identifikation datenorientierter Prozessdetails legt.

In Kapitel 5 wird die Einbindung der analysierten relevanten Prozessdetails in ein bestehendes Prozessmodell erläutert. Hierbei liegt der Schwerpunkt auf der Darstellung relevanter Details in existierenden Prozessmodellen durch das Anhängen der neu gewonnenen Informationen in Form von Aufgabenannotationen. Im Rahmen dieser Thematik wird eine experimentelle Nutzerstudie konzipiert und durchgeführt, deren Planung und Ergebnisse ausführlich präsentiert werden.

In Kapitel 6 erfolgt eine Untersuchung der Übertragbarkeit des Gesamtkonzepts auf weitere Domänen, wobei die Robotik als Beispiel herangezogen wird. In diesem Kontext wird erläutert, welche Schritte des Konzepts unter Einbezug von Prozess- und Domänenwissen Anpassung erfordern. Für die Anwendung in der Robotik werden insbesondere die Schritte zur Analyse und Integration von Prozessdetails erörtert, um damit verbundene Herausforderungen zur Berücksichtigung von Robotern und Roboteraufgabenmodellen

zu adressieren. Die Anwendbarkeit des Konzepts in der Robotikdomäne wird anhand eines Experimentaufbaus evaluiert, der an Prozessen orientiert ist, in denen typischerweise Roboter zur Ausführung eingesetzt werden.

In Kapitel 7 werden die Ergebnisse einer umfassenden Literaturrecherche zum Stand der Forschung zusammengefasst und themenverwandte Arbeiten strukturiert. Gleichzeitig erfolgt eine Abgrenzung der vorliegenden Arbeit von existierender Forschung und eine Einordnung in den Gesamtkontext.

Die Arbeit schließt in Kapitel 8 mit einer Zusammenfassung der erzielten Ergebnisse, begleitet von einem Ausblick auf zukünftige Forschungsrichtungen.

Die im Rahmen der Arbeit entwickelten Ansätze, durchgeführten Experimente und dadurch erzielten Ergebnisse sind teilweise bereits im Zuge der Forschungstätigkeiten zu dieser Dissertation veröffentlicht worden (,Thematisch relevante Publikationen‘ im Anhang). Die Inhalte dieser Publikationen sind in den entsprechenden Kapiteln (Kapitel 3, 4, 5 und 6) integriert und werden in den Gesamtkontext dieser Arbeit eingebettet. Dafür werden sie mit neuen Inhalten angereichert sowie durch umfassende Diskussionen und damit verbundenen Erkenntnissen ergänzt. Zu Beginn jedes Kapitels sind inhaltlich verknüpfte Publikationen gekennzeichnet.

2 | GRUNDLEGENDE ANSÄTZE ZUR PROZESS- MODELLVERBESSERUNG

Die **Prozessmodellverbesserung**, in der Literatur auch als **Prozessmodelloptimierung** (engl. *process model optimization*) bezeichnet, beschreibt den Vorgang der Verbesserung eines Prozessmodells hinsichtlich verschiedener Ziele. Ansätze aus diesem Bereich beschäftigten sich mit der Anpassung von Prozessmodellen bzgl. Aspekten, die während der Modellierungsphase nicht berücksichtigt worden sind. Darunter sind Methoden, welche sich mit den in Abschnitt 1.2.1 genannten Anforderungen an die Prozessmodellierung auseinandersetzen, für diese Arbeit von besonderer Bedeutung. Sie verbessern Prozessmodelle aus inhaltlicher (Anforderung 1) und darstellungstechnischer (Anforderung 2) Sicht. Dabei hat die Prozessmodellverbesserung das übergeordnete Ziel, die anschließende Ausführung und somit den abgebildeten Prozess zu verbessern. Insgesamt soll eine Steigerung der Leistung und eine Reduzierung der Kosten eines Prozesses erreicht werden [253]. Aus diesem Grund sind derartige Methoden in der Forschung auch im Kontext des Begriffs **Prozessverbesserung** bzw. **Prozessoptimierung** (engl. *process optimization*) zu finden. Prozessverbesserung ist ein weites Feld, weshalb zu betonen ist, dass der Fokus dieses Kapitels auf der Prozessmodellierung liegt. Methoden wie beispielsweise Simulationen oder Systeme zur Unterstützung von Mitarbeitenden während der Prozessausführung finden daher keine Berücksichtigung. Im Folgenden werden etablierte Modellverbesserungsansätze bzgl. der oben genannten Anforderungen vorgestellt und die dahinter liegenden Konzepte skizziert. Die damit verbundenen Erkenntnisse und Ideen bilden die Grundlage für den Forschungsansatz dieser Arbeit. Dieses Kapitel dient primär der Erarbeitung einer Zusammenfassung grundlegender Ansätze. Eine konkrete Abgrenzung der vorliegenden Arbeit zu den einzelnen Herangehensweisen folgt dagegen in Kapitel 7.

2.1 INHALTLICHE VERBESSERUNG

Ansätze zur inhaltsbezogenen Verbesserung von Prozessmodellen zielen explizit auf eine Erhöhung des Informationsgehalts eines Modells ab. Dabei wird ein Prozessmodell um

neue Informationen angereichert oder bereits in einem Modell enthaltene Prozessinformationen präzisiert, korrigiert oder neu angeordnet. Der Fokus liegt auf der Identifikation von Schwachstellen bzw. ‚Bottlenecks‘ eines Prozesses und einer Gegensteuerung durch entsprechende Anpassung des dazugehörigen Prozessmodells [128]. In [4] werden für die Umsetzung dieses Ziels zwei Methoden unterschieden. Zum einen können Analysen hinsichtlich der Korrektheit oder Leistung eines Prozessmodells durchgeführt werden. Zum anderen können Daten in Form von Ereignisprotokollen genutzt werden, um Prozessabläufe zu untersuchen und Modelle zu verbessern.

2.1.1 PROZESSMODELLANALYSE

Prozessmodellanalysen (engl. *process model analysis*) umfassen die Bewertung der Korrektheit und Leistung eines Prozessmodells [4]. Für die Korrektheitsanalyse kann beispielsweise die sog. *Soundness*, also die Solidität eines Prozessmodells überprüft werden [10]. Ist diese Eigenschaft erfüllt, treten im Modell keine zyklischen Wartebedingungen wie *Deadlocks* oder andere Anomalien auf, die auch ohne Domänenkenntnisse erkannt werden können. Dabei kommt häufig lineare temporale Aussagenlogik (engl. *Linear Temporal Logic* (LTL)) zum Einsatz. Durch die Aufstellung von LTL-Formeln wird die Wahrheit von Bedingungen überprüft, z.B. dass eine bestimmte Aufgabe im Prozessmodell immer als Letztes ausgeführt wird. Eine Übersicht an Methoden zur Bestimmung der *Soundness* von Modellen liefert [75]. Leistungsanalysen werden durch die Messung von Schlüsselkennzahlen (engl. *Key Performance Indicators* (KPIs)) zu verschiedenen Dimensionen durchgeführt. Dabei werden typischerweise KPIs zu Zeit, Kosten und Qualität gesammelt. Beispielsweise können diese in Ansätzen wie [217] genutzt werden, um das Prozessmodell hinsichtlich einer Ziel-KPI zu optimieren.

Der Nutzen einer Korrektheits- und Leistungsanalyse hängt entscheidend von der adäquaten Abbildung des realen Prozesses im Modell ab. Bewertungen der internen Konsistenz von Prozessmodellen sowie der Erfüllung von Leistungsanforderungen sind nur dann zielführend und für eine Verbesserung anwendbar, wenn das Modell einer realitätsnahen Repräsentation entspricht. Somit gilt das Vorhandensein bereits qualitativ hochwertiger Prozessmodelle als Vorbedingung für derartige Verbesserungsansätze. Mit der Erfüllung dieser Voraussetzung beschäftigen sich Techniken des nachfolgenden Abschnitts.

2.1.2 PROCESS MINING

Process Mining¹ beschreibt eine Gruppe von Verfahren zur Analyse von Daten, die von Softwaresystemen während der Ausführung realer Prozesse in Unternehmen gesammelt werden [4]. Sie leiten aus den Daten Informationen ab, die für eine Prozessmodell- und Prozessverbesserung genutzt werden können. Die gesammelten Daten umfassen üblicherweise historische Informationen zu Abläufen, wie Benutzeraktivitäten und Interaktionen, die in **Ereignisprotokollen** (engl. *event logs*) festgehalten sind. Aus diesen Datenbeständen wird neues Prozesswissen extrahiert, indem Ansätze aus dem Prozessmanagement mit Methoden aus dem Bereich Data Mining verbunden werden [6]. Dabei umfasst Process Mining drei Typen, die unterschiedliche Verbesserungsziele verfolgen [2]:

- (1) **Entdeckung** (engl. *discovery*) beschreibt die Extraktion von Prozessmodellen aus Ereignisprotokollen.
- (2) **Übereinstimmung** (engl. *conformance*) gleicht Prozessmodelle mit realen Prozessabläufen ab und ermöglicht die Identifikation von Abweichungen.
- (3) **Erweiterung** (engl. *enhancement*) reichert existierende Prozessmodelle um Informationen an, die aus Ereignisprotokollen stammen.

Abbildung 7 illustriert, wie die drei Typen² in ein Gesamtsystem einzuordnen sind. Dabei interagieren verschiedene Einheiten miteinander, bestehend aus der Prozessumgebung („Welt“), dem Softwaresystem, dem Bestand aus Ereignisprotokollen und dem Prozessmodell. Vor allem Methoden des ersten und dritten Process Mining-Typs sind für diese Arbeit in Hinblick auf inhaltliche Verbesserungen von Prozessmodellen von besonderem Interesse. Sie lösen Probleme, die durch die händische Erstellung von Prozessmodellen auftreten [4]. Eine gängige Technik ist beispielsweise das Durchführen von Assoziationsanalysen, um wichtige Zusammenhänge innerhalb der Ereignisprotokolle aufzudecken [14, 202, 237] (Abschnitt 4.5.1). So liefern Discovery-Ansätze möglicherweise andere Ergebnisse als eine händische Modellierung, da sie ein Prozessmodell auf Basis versteckter Prozessinformation erzeugen, die zum Modellierungszeitpunkt noch unbekannt war. Daneben reichern Methoden aus dem Gebiet Enhancement Prozessmodelle um Prozessinformationen an und ermöglichen somit eine Verbesserung unter Berücksichtigung bereits bestehender Information. In Kapitel 7 werden Ansätze aus diesen beiden Bereichen im Zusammenhang mit der vorliegenden Arbeit näher betrachtet und eingeordnet.

¹ ‚Process Mining‘ ist ein feststehender Begriff in der Wissenschaft und wird in dieser Arbeit mit seinem englischen Terminus verwendet.

²Im weiteren Verlauf der Arbeit werden die Process Mining-Methoden ‚Discovery‘, ‚Conformance‘ und ‚Enhancement‘ mit ihren entsprechenden englischen Fachtermini verwendet.

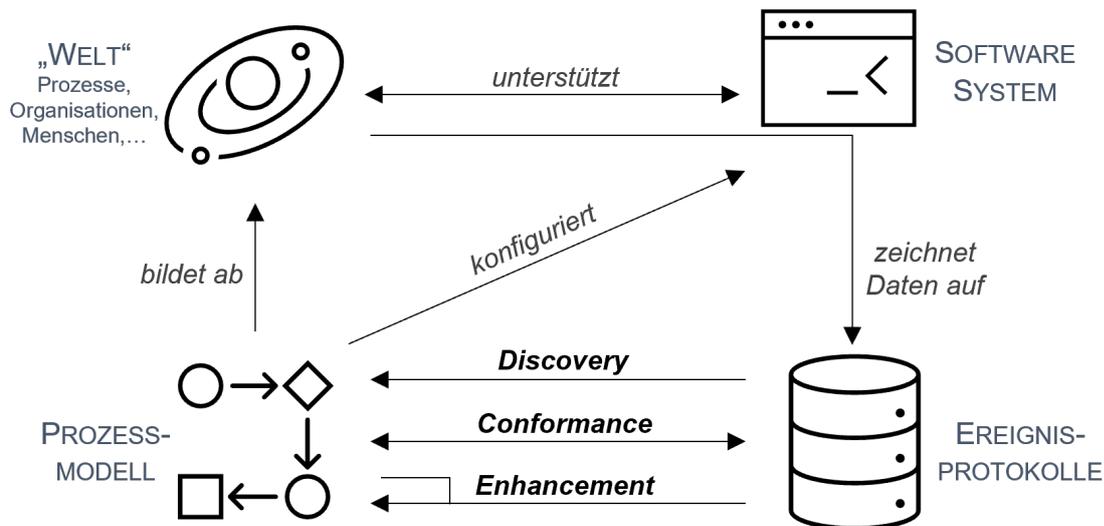


Abbildung 7: Process Mining-Typen (*Discovery*, *Conformance*, *Enhancement*) nach [2].

2.2 VERBESSERUNG DER LESBARKEIT

Die Lesbarkeit eines Prozessmodells nimmt direkten Einfluss auf Entwicklung, Effizienz und Kosten eines Prozesssystems [88]. Darüber hinaus unterstützen verständliche Modelle nicht nur den Zugang zu Prozessinformationen, sondern ermöglichen auch deren Umsetzung, wie ursprünglich von ModelldesignerInnen bzw. ProzessexpertInnen vorgesehen. Die Lesbarkeit eines Prozessmodells hängt dabei von zwei Faktoren ab. Zum einen davon, wie die Zielgruppe die enthaltene Information interpretiert. Zum anderen sind die Qualität des Modells und der damit verbundene Aufwand während des Erstellungsprozesses entscheidend sowie in welchem Format Information dargestellt ist [97]. Eine grundlegende Idee zur Unterstützung dieser Aspekte besteht in der Entwicklung und Bereitstellung verschiedener Modellierungssprachen. Sie ermöglichen Prozesse auf unterschiedliche Weise zu visualisieren und streben durch vorgegebene Elemente und Regeln an, klare Kommunikationsstrukturen zu schaffen. Andere Ansätze befassen sich konkret mit Prozessmodellen selbst und versuchen durch Restrukturierungen und Abstraktionsmechanismen Prozessmodelle lesbarer zu gestalten.

2.2.1 MODELLIERUNGSSPRACHEN UND DARSTELLUNGSFORMATE

Frühe Prozessmodelle sind durch einfache grafischen Darstellungen wie Flussdiagramme gekennzeichnet [275]. Basierend auf dieser Darstellungsweise haben sich eine Vielzahl von Modellierungssprachen entwickelt (z.B. BPMN, UML, EPC), die außerdem eine eindeutige formale Modellierungssemantik bereitstellen. Dabei ist die Verwendung

grafischer Notationen dominierend, da sie als benutzerfreundlich und verständlich gelten [96, 110, 191]. Im Vergleich zu Texten ermöglichen Diagramme eine Strukturierung von Inhalten, um Abläufe übersichtlicher zu gestalten. Allerdings führen komplexe Prozesse und Beschreibungen zu umfangreichen und nicht mehr nachvollziehbaren Prozessmodellen. In solchen Fällen stoßen diagrammbasierte Darstellungen an ihre Grenzen. Die Verwendung von alternativen **Repräsentationsformaten** für die Darstellung von Prozessen, wie beispielsweise Bildern, Listen, Symbolen oder auch hybriden Varianten mit Diagrammen, sind ein relevantes Thema in der Forschung zu Prozessmodellen [88, 198, 279] (Abschnitt 5.1). Für bestimmte Informationen ermöglichen diese Formate im Gegensatz zu Diagrammen eine kompaktere und damit verständlichere Darstellung sowie die gezielte Hervorhebung spezifischer Aspekte. Neben der Untersuchung verschiedener Darstellungsformate existieren weitere Ansätze, die eine Erhöhung der Lesbarkeit von Prozessmodellen anstreben. Darunter finden sich beispielsweise Verbesserungsansätze, die bestehende Modellierungssprachen erweitern, oder die neue Sprachen bzw. Modellierungsparadigmen definieren.

Erweiterungen von bisherigen und etablierten Modellierungssprachen wie BPMN sind beispielsweise in [282] entwickelt worden. Gemäß diesem Ansatz können Mediadateien an Aufgaben in BPMN-Modellen angehängt werden, um die Struktur und Übersichtlichkeit eines Prozessmodells zu wahren und dabei gleichzeitig um komplexe Informationen anzureichern. Auf diesen Ansatz wird noch einmal näher in Abschnitt 5.4.2 eingegangen.

Für Prozesse mit zahlreichen Ausführungsalternativen sind bekannte Modellierungssprachen wie BPMN, UML oder EPC grundsätzlich nicht geeignet. Sie sind Beispiele sog. imperativer Modellierungsansätze, in denen sämtliche Ausführungsalternativen explizit im Prozessmodell spezifiziert werden müssen, was zu umfangreichen und komplexen Diagrammen führt. Infolgedessen haben sich neben imperativen Modellierungssprachen deklarative Herangehensweisen entwickelt. Sie folgen einem „von außen nach innen“-Schema (engl. *outside-to-inside*) [199], wobei alle Tätigkeiten im Rahmen eines Prozesses erlaubt sind und lediglich Einschränkungen explizit im Prozessmodell angegeben werden. Deklarative Modellierungssprachen ermöglichen durch derartige Regeln die Bewahrung der Lesbarkeit komplexer Prozessmodelle, in denen der Fokus auf Abhängigkeiten zwischen Aufgaben und Bedingungen liegt. In der Literatur sind dazu außerdem Entwicklungen zu finden, die sich mit hybriden Modellierungsparadigmen auseinandersetzen, um die Lesbarkeit von Modellen weiter zu verbessern [239, 249].

2.2.2 ABSTRAKTION UND AGGREGATION

Um die Übersichtlichkeit von Prozessmodellen zu wahren, empfehlen allgemeine Modellierungsleitfäden die Anzahl verwendeter Elemente zu reduzieren und somit Prozessmodelle möglichst minimal zu halten [147, 168]. Die praktische Umsetzung dieser Anforderung bedeutet zum einen, Verzweigungselemente anstatt mehrerer ausgehender und eingehender Kontrollflüsse zu verwenden und zum anderen, insgesamt weniger Aufgaben zu modellieren [141]. Bezüglich des letzten Aspekts sind Abstraktions- und Aggregationsmechanismen entwickelt worden, welche existierende Prozessmodelle hinsichtlich ihrer Lesbarkeit verbessern [38, 203, 215, 251]. Derartige Methoden reduzieren die Anzahl an Elementen in einem Prozessmodell und akzeptieren Informationsverlust zugunsten der Verbesserung der Lesbarkeit. Abbildung 8 zeigt, wie beispielsweise in [38] abstrahierte Sichten auf ein Prozessmodell erzeugt werden können, in dem Aufgaben aggregiert oder reduziert werden. Reduktionsmechanismen eliminieren ganze Aufgaben und damit verbundene Informationen. Aggregationsmechanismen fassen Aufgaben zusammen, wobei dadurch entstehende kumulierte Aufgaben (z.B. hier BCHK) neue Beschriftungen erhalten. Diese benennen entweder zusammenfassend die Inhalte der ursprünglichen Aufgabenbeschreibungen in abstrahierter Form oder entsprechen einfachen Aneinanderreihungen der vorherigen Beschreibungen. Die Anpassung der neuen Beschriftung erfolgt dabei ebenfalls unter Berücksichtigung der Lesbarkeit.

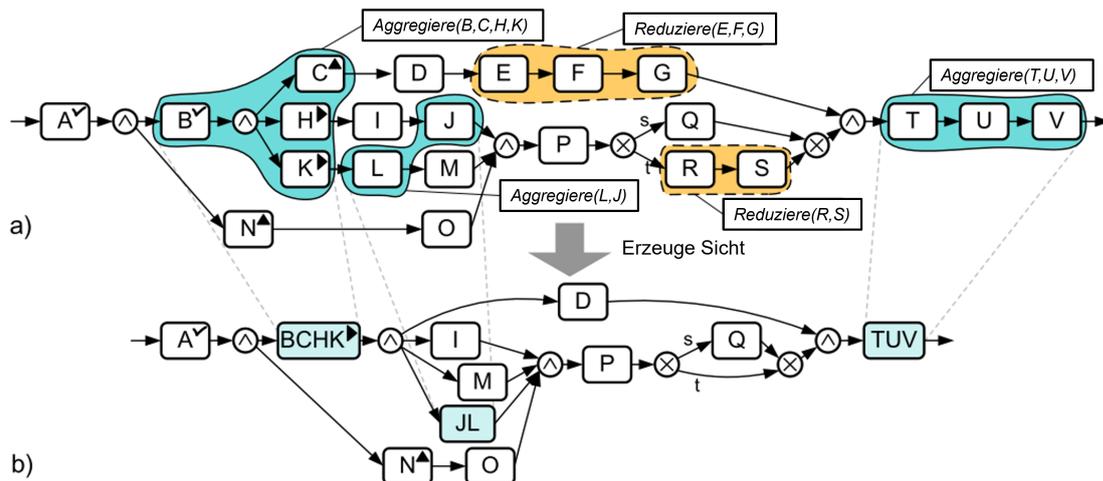


Abbildung 8: Illustration der Erzeugung einer Sicht auf ein Prozessmodell nach [38].

2.3 ZUSAMMENFASSUNG

In diesem Kapitel werden verschiedene Methoden zur Verbesserung von Prozessmodellen erläutert, um einen Überblick über grundlegende Herangehensweisen zu gewinnen. Hierbei erfolgt eine Differenzierung zwischen Ansätzen, die auf eine Erhöhung der in einem Prozessmodell enthaltenen Informationen abzielen und solchen, die eine Steigerung der Lesbarkeit eines Modells anstreben. Die betrachteten Forschungsrichtungen verdeutlichen die Relevanz dieser Themen und legen nahe, dass beide Dimensionen in gleichem Maße bei der Modellverbesserung berücksichtigt werden müssen. Untersuchungen zur Verständlichkeit von Prozessmodellen zeigen, dass große, informationsüberladene Modelle und unverständliche Repräsentationsformate vermieden werden müssen, da sie erheblich die Effektivität und Effizienz einer Ausführung beeinträchtigen. Die Auswahl einer geeigneten Modellierungssprache sowie die Fokussierung auf eine möglichst kleine Menge an Informationen sind dabei unerlässlich. Dagegen wird im Kontext der inhaltlichen Modelloptimierung vielmehr hervorgehoben, dass eine zielgerichtete Verbesserung der Prozessleistung eine Erhöhung der inhaltlichen Aspekte von Modellen erfordert. Exemplarisch dient die Anwendung von etablierten Ansätzen wie Process Mining, welche die Modelle durch Integration von Informationen aus Ereignisprotokollen substanziell bereichern. Ein unzureichender Informationsgehalt eines Prozessmodells führt dazu, dass selbst eine ansonsten gut lesbare Darstellung an Signifikanz verliert. Für die vorliegende Arbeit ist damit von fundamentaler Bedeutung, Erkenntnisse sowohl aus Ansätzen zur Verbesserung der Informationsqualität als auch aus solchen zur Steigerung der Lesbarkeit zusammenzuführen. Das basierend auf dieser Zielsetzung entwickelte Gesamtkonzept fungiert dabei als Schlüsselement, das eine Brücke zwischen diesen beiden konfligierenden Verbesserungsrichtungen schafft.

3 | GESAMTKONZEPT ZUR VERBESSERUNG VON PROZESSMODELLEN DURCH RELEVANTE PROZESSDETAILS

Im Folgenden wird das entwickelte Gesamtkonzept beschrieben, das sich mit der Beantwortung der zentralen Forschungsfrage aus Abschnitt 1.3 befasst, d.h. wie Prozessmodelle durch relevante Prozessdetails verbessert werden können. Ziel ist die Schaffung eines Rahmenwerks zur Erfüllung der gleichzeitig geltenden Modellierungsanforderungen und Schließung der damit verbundenen Forschungslücke.

Dafür wird zunächst auf die Entstehung des Konzepts eingegangen und die getroffenen Designentscheidungen erläutert. Diese umfassen die grundlegenden Prinzipien und Methoden, die bei der Entwicklung angewendet worden sind (Abschnitt 3.1). Darauf aufbauend werden die verschiedenen Phasen des Konzepts im Detail vorgestellt (Abschnitt 3.2). Hierbei wird insbesondere auf die Schritte der Verbesserungsphase eingegangen, die eine zentrale Rolle im Verfahren einnehmen (Abschnitt 3.3). Anschließend werden getroffene Annahmen des Konzepts sowie Bedingungen erläutert, die für eine effektive Umsetzung erfüllt sein müssen (Abschnitt 3.4). Ein weiterer Schwerpunkt liegt auf der Diskussion der Vor- und Nachteile diverser Datenquellen und ihre Nutzbarkeit zur Extraktion verschiedener Typen relevanter Prozessdetails (Abschnitt 3.5). Inhalte dieses Kapitels sind teilweise bereits in den Publikationen [81, 83, 84] veröffentlicht. Im Folgenden werden sie jedoch wesentlich detaillierter erläutert, formalisiert und um zusätzliche Aspekte zum Hintergrund sowie der Anwendung des Gesamtkonzepts ergänzt.

3.1 HINTERGRUND

Die Gestaltung des Gesamtkonzepts ist maßgeblich vom Prozesslebenszyklus inspiriert (Abschnitt 1.1.1). Der Lebenszyklus verfolgt das Ziel der inkrementellen Prozessverbesserung aus einer allgemeinen und abstrakten Perspektive heraus. Er stellt einen Rahmen

dar, der so konzipiert ist, dass er je nach spezifischem Anwendungsfall und Domäne adaptiert werden kann. Einzelne Schritte im Zyklus können prozessbezogen instanziiert und pro Durchlauf vollständig weggelassen oder inhaltlich ersetzt werden. Diese Flexibilität wird außerdem durch variierende Darstellungen verdeutlicht [5, 270].

Um an die vorteilhaften Eigenschaften des Prozesslebenszyklus anzuknüpfen, wird seine Vorgehensweise auf das entwickelte Gesamtkonzept übertragen. Die Verbesserung von Prozessmodellen durch relevante Prozessdetails erfolgt somit ebenfalls inkrementell, während einzelne Schritte entsprechend einer Anwendungsdomäne zugeschnitten werden können. Zur besseren Veranschaulichung und zum leichteren Verständnis der inkrementellen Vorgehensweise wird das Gesamtkonzept in drei Phasen unterteilt. Im Rahmen der Vorstellung der einzelnen Phasen im nachfolgenden Abschnitt wird die Abbildung auf den Prozesslebenszyklus noch einmal genauer betrachtet.

Das Gesamtkonzept unterliegt spezifischen Designentscheidungen, die zum einen im Zusammenhang mit Zielsetzungen stehen und zum anderen auf Annahmen und Bedingungen basieren, die für eine effektive Anwendung erfüllt sein müssen. Detaillierte Anforderungen für einzelne Phasen oder Schritte des Konzepts werden im weiteren Verlauf in den entsprechenden Abschnitten näher erläutert. Wesentliche Bedingungen, die bei der Anwendung des Gesamtkonzepts berücksichtigt werden müssen, werden gesondert in Abschnitt 3.4 beschrieben. An dieser Stelle wird jedoch kurz auf zwei Aspekte hingewiesen, die vor der eigentlichen Entwicklung des Konzepts entschieden worden sind und damit grundlegende Anforderungen enthalten:

1. Die Anwendung des entwickelten Verbesserungsansatzes darf den regulären Ablauf eines Unternehmens nicht beeinträchtigen. Es ist entscheidend, dass das Konzept nahtlos in bestehende Prozessumgebungen integriert werden kann, ohne den Betrieb zu unterbrechen oder negativ zu beeinflussen (z.B. durch das Verursachen von Verzögerungen). Dadurch wird sichergestellt, dass in jedem Fall eine Prozessverbesserung stattfindet und der Prozess realitätsnah betrachtet wird. Um dies zu erreichen, ist das Konzept so entworfen, dass die eigentliche Verbesserung **offline** erfolgt, d.h. außerhalb des laufenden Betriebs. Auf diese Weise wird sichergestellt, dass die Prozessumgebung und die in ihr stattfindenden Aktivitäten vor möglichen Beeinträchtigungen durch lange Berechnungen oder Untersuchungen unberührt bleiben. Die Datensammlung, die als Grundlage für diese Verbesserung dient, erfolgt jedoch **online** und muss demnach entsprechend in den Prozessablauf integriert werden. Dies schließt unter Umständen die Verwendung von bestimmten Datenquellen aus, was in Abschnitt 3.5 näher diskutiert wird.

2. Eine weitere Zielsetzung besteht im Finden relevanter Prozessdetails zur Steigerung des Prozesserfolgs im Kontext von bereits definierten Unternehmensabläufen. Damit verbunden setzt das entwickelte Verfahren die Existenz eines Prozessmodells voraus. Außerdem müssen die darin enthaltenen Informationen einem bestimmten Abstraktionsniveau entsprechen. Das Prozessmodell muss also grundsätzlich Potenzial für eine Optimierung mit relevanten Prozessdetails bieten. Das bedeutet, es enthält nur grobe Aufgabenanweisungen und keine detaillierten Informationen zur Prozessausführung. Als Konsequenz einer zu groben Aufgabenanweisung wird angenommen, dass eine beobachtbare Abweichung in den einzelnen Prozessergebnissen vorliegt. Diese Abweichungen dienen als Grundlage, um fehlende Detailinformationen finden zu können. In diesem Zusammenhang gibt es noch weitere Anforderungen für die Analyse der aufgenommenen Daten, die in Abschnitt 3.3.4 erläutert werden.

3.2 DREI PHASEN DES GESAMTKONZEPTS

Das Gesamtkonzept wird in drei Phasen unterteilt, die nacheinander durchlaufen werden und in Abbildung 9 zusammengefasst sind. In jeder Phase wird ein gegebenes Prozessmodell ausgeführt und die daraus resultierenden Prozessergebnisse betrachtet. Dabei unterscheiden sich die Phasen wie folgt.

In einem ersten Schritt wird die **Beobachtungsphase** durchgeführt. Sie ermöglicht es, Schwachstellen in einem Prozess zu erkennen und den Bedarf für mögliche Verbesserungen zu identifizieren. Die Phase ist als vorbereitender Schritt zu verstehen, in der ProzessexpertInnen bei der Ausführung eines gleichbleibenden Prozessmodells Abweichungen im Prozessergebnis beobachten. Diese können beispielsweise durch Datenerfassung von Prozesskennzahlen oder Qualitätskontrollen des Endprodukts festgestellt werden. Variieren Prozessergebnisse in ihrer Qualität oder werden unterschiedliche Kosten und Ausführungszeiten pro Prozessdurchlauf festgestellt, ist dies ein Indiz für eine unzureichende Prozessmodellierung. Zur näheren Analyse und Lösung des Problems wird in solchen Fällen folglich die Verbesserungsphase angestoßen.

Die zweite Phase, die **Verbesserungsphase**, bildet das Herzstück des Gesamtkonzepts. Sie besteht aus insgesamt fünf Schritten, in denen ausgewählte Aufgaben innerhalb eines Prozessmodells sukzessive hinsichtlich relevanter Prozessdetails verbessert werden. Im nachfolgenden Abschnitt 3.3 werden die einzelnen Schritte im Detail erläutert. Zu den Schritten gehören unter anderem die Analyse und Integration der Prozessdetails, die aufgrund ihrer Komplexität als eigenständiger Beitrag zu betrachten sind. Als Grundlage für

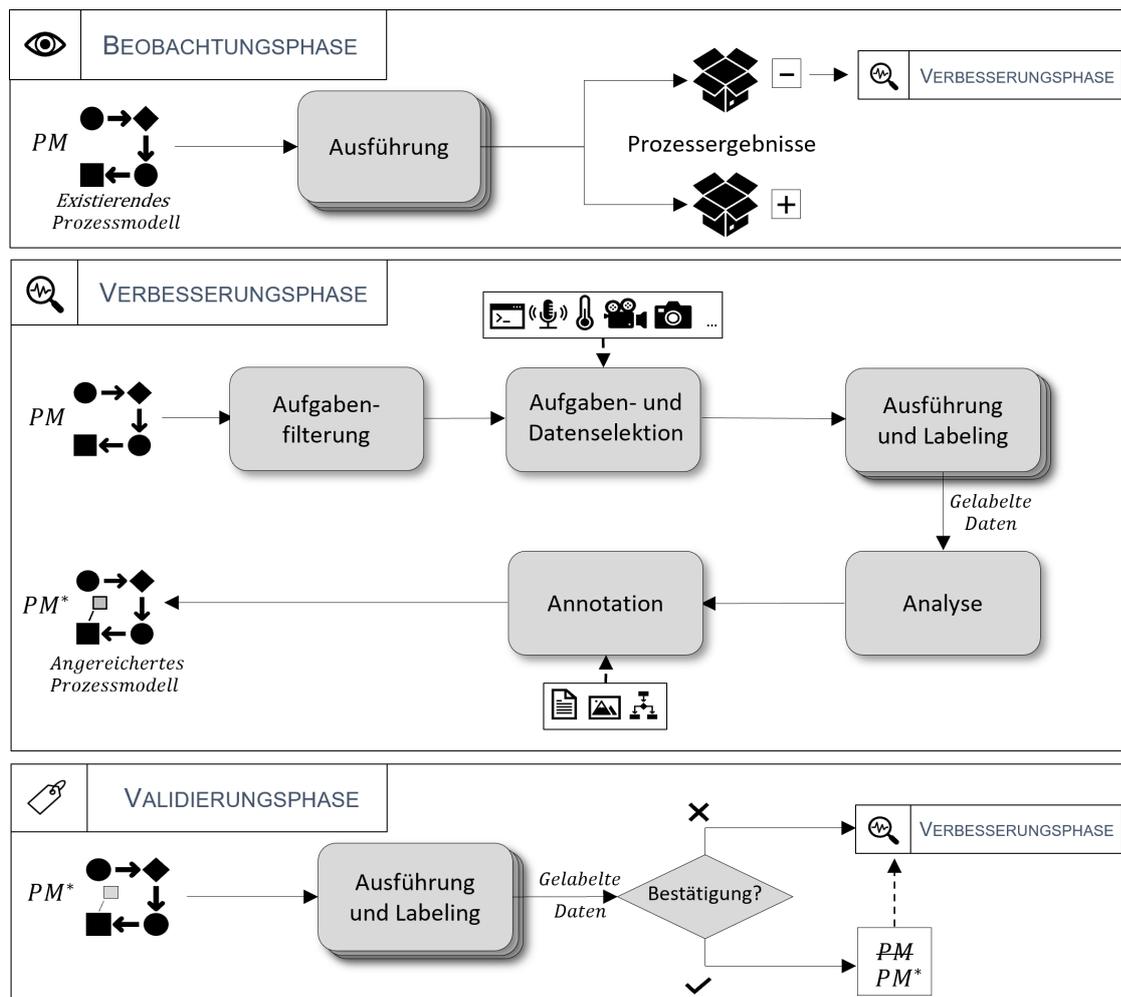


Abbildung 9: Entwickeltes Gesamtkonzept mit drei Phasen zur inkrementellen Erweiterung von Prozessmodellen (PM) durch relevante Prozessdetails nach [81].

den Analyseschritt werden in dieser Phase zudem Prozessinformationen aus verschiedenen Datenquellen durch mehrmaliges Ausführen desselben Prozessmodells gesammelt. Diese Daten werden schließlich am Ende jeder Ausführung implizit von einem Experten bzw. einer Expertin bewertet, indem das Prozessergebnis in Hinblick auf den geplanten Prozesserfolg beurteilt wird. Solche mit **Labeln**¹ versehenen Daten stellen eine notwendige Bedingung für die Anwendung des Konzepts dar. Die Daten können dabei entweder neu gesammelt werden oder aus früheren Ausführungen hervorgegangen sein. Das Ergebnis dieser Phase ist ein mit relevanten Prozessdetails angereichertes Modell, das als Grundlage für die sich dann anschließende Validierungsphase dient.

Die **Validierungsphase** bildet die dritte Phase des Gesamtkonzepts. In ihr wird der Grad der Verbesserung überprüft, der durch die Integration relevanter Prozessdetails im

¹Der englische Begriff ‚Label‘ oder ‚Labeling‘ bezeichnet die Zuordnung einer Datei zu einer Kategorie, hier z.B. Prozesserfolg oder Prozessfehlschlag. Solche Daten werden als ‚gelabelte‘ Daten bezeichnet.

Modell erzielt wird. Dafür wird das angereicherte Prozessmodell mehrmals ausgeführt und die Prozessergebnisse erneut hinsichtlich des gewählten Erfolgskriteriums (z.B. Produktqualität) aus den vorherigen Phasen gelabelt. So kann quantitativ überprüft werden, in welchem Ausmaß die vorgenommene Veränderung zu einem Anstieg positiver Prozessergebnisse führt. Prozessexpertise spielt eine entscheidende Rolle in dieser Phase, da unter Einbezug des insgesamt erreichten Unternehmensfortschritts das angepasste Prozessmodell akzeptiert oder abgelehnt wird. Die Implementierung des angereicherten Modells gewährleistet nicht zwangsläufig eine umfassende Verbesserung des gesamten Unternehmensprozesses. Beispielsweise können durch die Berücksichtigung des analysierten Details wiederum in anderen Prozessen im Unternehmen, die nicht Teil des optimierten Modells sind, Nachteile oder Einschränkungen entstehen. In anderen Fällen kann die Umsetzung der identifizierten Verbesserung mit hohen Kosten verbunden sein. In der Praxis obliegt es ProzessexpertInnen, nicht nur die unmittelbaren Auswirkungen von Prozessveränderungen abzuschätzen, sondern auch die indirekten Einflüsse auf andere Aspekte im Unternehmen zu betrachten, die über den Umfang des Prozessmodells hinausgehen. Bei Bestätigung der Änderung im Prozessmodell, wird das ursprüngliche Prozessmodell verworfen und das angepasste Modell dient als Grundlage für zukünftige Prozessausführungen. Im Gegensatz zur Beobachtungsphase bildet die Validierungsphase gemeinsam mit der Verbesserungsphase einen zyklischen Prozess. Eine erneute Initiierung der Verbesserungsphase ist möglich, um eine andere Aufgabe im Prozessmodell zu analysieren oder für die Analyse andere Datenquellen auszuwählen.

Die Aufteilung des Gesamtkonzepts in drei Phasen ist motiviert durch [270], bei dem der Prozesslebenszyklus ebenfalls dreigeteilt ist. Durch die Aufteilung wird die Prozessentwicklung, die durch die einzelnen Durchläufe des Zyklus erfolgt, herausgearbeitet und eine präzisere Grundlage für einen konkreten Prozess geschaffen. Dennoch lassen sich die drei Phasen auch auf die Darstellung des Prozesslebenszyklus von [69] (Abschnitt 1.1.1) abbilden, wodurch eine einfache Einbettung in andere Prozessoptimierungskonzepte ermöglicht wird. Dafür entsprechen alle Phasen des Gesamtkonzepts jeweils verschiedenen Iterationen des Zyklus. Da jede Phase des Gesamtkonzepts eine (mehrmalige) Ausführung des Prozessmodells beinhaltet, sind insgesamt drei Durchläufe des Zyklus nötig (vgl. Abbildung 10). Die einzelnen Schritte des Lebenszyklus sind durchnummeriert, wobei Schritt 1 der ‚Prozessentdeckung‘ und Schritt 5 der ‚Prozessüberwachung und -steuerung‘ entspricht. Für das Gesamtkonzept wird angenommen, dass aufgrund vorheriger Durchläufe bereits ein Prozessmodell existiert. Aus diesem Grund entfällt der Einstiegspunkt der Prozessidentifikation und ist nicht in die Nummerierung einbezogen. Innerhalb einer Zyklusiteration werden außerdem je nach Phase einzelne Schritte übersprungen (gestrichelt dargestellt).



Abbildung 10: Die drei Phasen des Gesamtkonzepts werden auf verschiedene Iterationen und Schritte (1 bis 5) des Prozesslebenszyklus von [69] abgebildet.

Die Beobachtungsphase entspricht dem ersten der drei Durchläufe. Sie umfasst eine Konformitätsprüfung des aktuellen Prozessmodells, bei der Probleme des Prozessergebnisses durch mehrmaliges Ausführen festgestellt werden. Somit liegt der Fokus auf dem Schritt ‚Prozessüberwachung und -steuerung‘. Anschließend erfolgt die Prozessverbesserung, welche den zweiten Durchlauf und die erste Hälfte des dritten Durchlaufs des Prozesslebenszyklus einnimmt. Dabei treten zunächst vor allem die ‚Prozessentdeckung‘ und ‚Prozessüberwachung‘ in den Vordergrund. An dieser Stelle übernimmt die Prozessentdeckung nicht, wie ursprünglich definiert, die Aufgabe Prozesse zu modellieren, sondern das Ist-Prozessmodell für eine Analyse (durch Auswahl der zu analysierenden Aufgaben) vorzubereiten (Abschnitte 3.3.1 und 3.3.2). Zur Sammlung des Datenbestands für die Analyse wird der Prozess danach mehrmals ausgeführt (Abschnitt 3.3.3). Anschließend erfolgt in der ersten Hälfte des dritten Durchlaufs des Lebenszyklus die Instantiierung der Schritte ‚Prozessanalyse‘ (Abschnitt 3.3.4) und ‚Prozessumgestaltung‘ (Abschnitt 3.3.5) mit dem Ergebnis eines um relevante Prozessdetails angereicherten Modells. In der Validierungsphase wird dann als zweiter Teil dieses Durchlaufs das ergänzte Modell mehrmals ausgeführt und das Prozessergebnis überwacht. Damit liegt der Fokus dieser Phase auf der ‚Implementierung‘ des erweiterten Prozessmodells und der ‚Prozessüberwachung‘.

3.3 SCHRITTE DER VERBESSERUNGSPHASE

In den folgenden Abschnitten werden die fünf Schritte der Verbesserungsphase eingehend erläutert sowie Eingabe- und Ausgabeparameter für eine präzisere Darstellung formalisiert (vgl. Abbildung 11). Die Anwendung der einzelnen Schritte wird anhand eines laufenden Beispiels verdeutlicht. Dabei dienen Tätigkeiten aus Herstellungsprozessen im Kontext der Automobilproduktion zur Veranschaulichung.

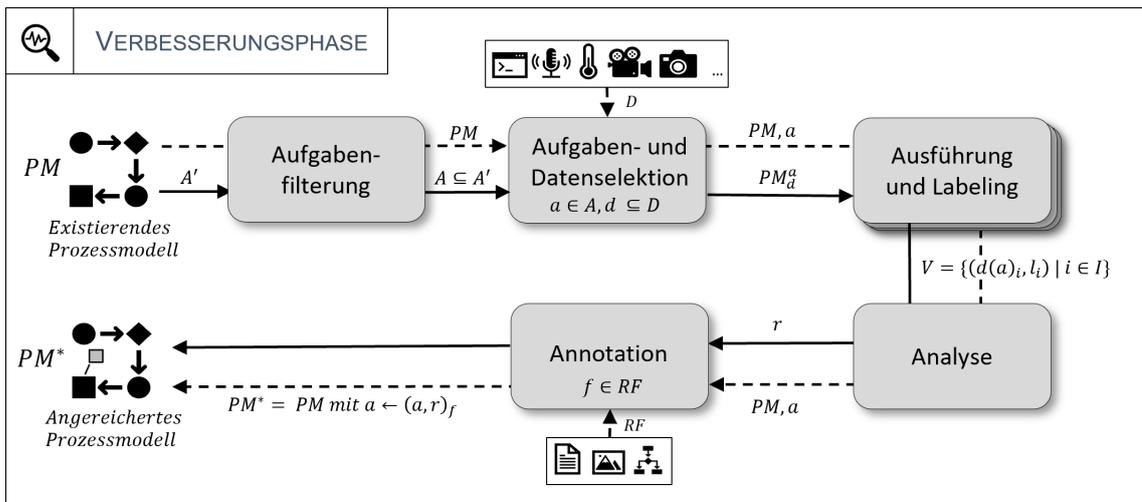


Abbildung 11: Formalisierte Darstellung der Verbesserungsphase in Anlehnung an [81].

3.3.1 AUFGABENFILTERUNG

Eingabe des Schritts ‚Aufgabenfilterung‘ ist ein in einer beliebigen Modellierungssprache erstelltes Prozessmodell PM , das die Grundlage für die Prozessausführung eines Unternehmens bildet. Zur konkreteren Erläuterung wird der Definition von [38] gefolgt und PM als Prozessgraph repräsentiert, der aus Aktivitäten und Kontrollkanten sowie strukturellen Elementen (z.B. UND- oder ODER-Verzweigungen) besteht:

Definition 3 (Prozessmodell). Ein Prozessmodell ist ein Tupel $PM = (N, E, EC, NT)$ mit:

- N beschreibt eine Menge an Knoten;
- $E \subset N \times N$ ist eine Menge von gerichteten Kanten mit $e = (n_{Start}, n_{Ziel}) \in E$;
- $EC : E \rightarrow \text{Bedingungen} \cup \{True\}$ weist Kanten Übergangsbedingungen zu;
- $NT : N \rightarrow \{\text{Aktivität, UND-Verzweigung, UND-Vereinigung, ODER-Verzweigung, ODER-Vereinigung, XOR-Verzweigung, XOR-Vereinigung, Ereignis}\}$ weist jedem Knoten $n \in N$ einen Typ $NT(n)$ zu; dabei lässt sich N in disjunkte Mengen von Aktivitätsknoten $K(NT(n) = \text{Aktivität})$ und Strukturknoten $S(NT(n) \neq \text{Aktivität})$ unterteilen. Neben Subprozessen und Aufruf-Aktivitäten (engl. call activities), kann K Aufgaben verschiedenen Typs enthalten (z.B. manuelle Aufgaben oder Sende-Aufgaben (engl. send tasks)). Die Menge aller Aufgaben wird als $A' \subseteq K$ bezeichnet.

Im Rahmen der Aufgabenfilterung wird aus PM zunächst die Menge aller Aufgaben A' extrahiert. Anschließend werden die Aufgaben herausgefiltert, die nicht manuell von Prozessteilnehmenden auszuführen sind. Folglich bleibt die Menge der manuell auszuführenden Aufgaben $A \subseteq A'$ als Eingabe für den nächsten Schritt der Phase übrig. Dabei ist

zu erwähnen, dass grundsätzlich alle Aufgabentypen im Konzept verarbeitet werden können. Manuell auszuführende Aufgaben, d.h. händische Tätigkeiten, beinhalten jedoch das größte Verbesserungspotenzial, da bei diesen Aufgaben die Interpretation der Anweisungen von Menschen erfolgt. Dies beinhaltet einen gewissen Interpretationsspielraum, wie eine abstrakte Aufgabenanweisung ausgeführt werden soll, was sich in unterschiedlichen Ausführungen niederschlägt. In solchen Szenarien ist die Analyse relevanter Prozessdetails äußerst nützlich, um die Ursache für auftretende Abweichungen aufzuklären.

Beispiel: In der Automobilfertigung erfolgen beispielsweise Prozessschritte wie die Lackierung von Karosserieteilen automatisiert durch Maschinen, während dagegen die Montage komplexer Bauteile häufig noch händisch durch MitarbeiterInnen durchgeführt wird. Im Weiteren wird angenommen, dass durch die Aufgabenfilterung zwei manuell auszuführende Montageschritte im einem Prozessmodell identifiziert werden, z.B. die Montage der Feinelektronik und die Montage des Sound-Systems.

3.3.2 AUFGABEN- UND DATENSELEKTION

Aus der Menge manuell auszuführender Aufgaben A wird anschließend eine Aufgabe $a \in A$ ausgewählt, die im Fokus der darauffolgenden Schritte steht. Die anderen Aufgaben können später durch das erneute Ausführen der Verbesserungsphase betrachtet werden (Abschnitt 3.2). Für den Ansatz spielt es deshalb grundsätzlich keine Rolle, welche Aufgabe zuerst betrachtet wird. Allerdings kann eine Priorisierung sinnvoll sein, sofern Kontextwissen vorliegt. Diese Entscheidung wird entweder von ProzessexpertInnen getroffen oder es werden alternative Kriterien herangezogen. Beispielsweise können Aufgaben, zu denen insgesamt am wenigsten Information im Modell vorliegt, für die Analyse bevorzugt werden. Als Nächstes wird aus einer Reihe verfügbarer Datenquellen D eine Datenquelle $d \in D$ ausgewählt. Diese ist entweder bereits in der Prozessumgebung vorhanden oder wird bewusst für die Analyse relevanter Details installiert. Bei der Ausführung von a werden dann Daten bzgl. d in dem dazugehörigen Format gesammelt. Je nach Prozessumgebung und -kontext können einige Datentypen besser für den Analyseschritt geeignet sein. Außerdem ermöglichen nicht alle Datentypen die Analyse bestimmter Arten von Prozessdetails. In Abschnitt 3.5 werden diese Aspekte genauer diskutiert. Im Schritt ‚Aufgaben- und Datenselektion‘ besteht grundsätzlich die Möglichkeit, mehrere Datenquellen gleichzeitig zu aktivieren (in Abbildung 11 gekennzeichnet durch $d \subseteq D$), um Daten während der Ausführung von a zu sammeln. Zur besseren Illustration und Umsetzung wird sich im Folgenden jedoch auf die Auswahl einer Datenquelle pro Durchlauf der Verbesserungsphase beschränkt. Neben einer Anpassung der Prozessumgebung zur Aufzeichnung von Daten durch die ausgewählte Datenquelle (z.B. Einrichten bestimmter Systeme) wird das

Prozessmodell PM zu PM_d^a umdefiniert, sodass Daten während der Ausführung von a gemäß d (automatisch) erfasst werden können.

Beispiel: Aus der gefilterten Aufgabenmenge wird zunächst der Schritt zur Montage der Feinelektronik selektiert. Dabei wird beispielsweise diese Aufgabe für eine eingehende Analyse ausgewählt, da sie im Prozessmodell weniger detailliert beschrieben wird, als der Schritt zur Sound-System-Montage. Als Quelle für die Datenerfassung wird ein Kamerasystem eingerichtet, mit dem Videos der Montage aufgenommen werden.

3.3.3 AUSFÜHRUNG UND LABELING

Anschließend wird PM_d^a ausgeführt und Ausführungsdaten zu a mithilfe der gewählten Datenquelle d aufgenommen. Dabei können Daten vor, während oder nach der Aufgabenausführung gesammelt werden. Der Zeitpunkt der Datenaufnahme hängt vom jeweiligen Prozess und der gewählten Datenquelle ab. Jeweils nach einem vollständigen Durchlauf von PM_d^a wird das gesammelte Datum in Hinblick auf den **gesamten** Prozess Erfolg gelabelt. Der Prozess Erfolg kann auf unterschiedliche Weise definiert werden und hängt vom Optimierungsziel ab. Wird das vorgestellte Gesamtkonzept zur Verbesserung der Prozessergebnisqualität angewendet, erfolgt das Labeling der Daten entsprechend dieses Kriteriums. Es sind jedoch auch andere Kriterien denkbar, wie zum Beispiel die Produktionsdauer oder die Produktionskosten [55]. Das Labeling der Daten am Ende eines gesamten Durchlaufs des betrachteten Prozesses ist von fundamentaler Bedeutung für die Effektivität des Konzepts und eröffnet die Möglichkeit für eine innovative Herangehensweise. Klassische Prozessoptimierungsansätze, so wie sie zum Beispiel im Bereich der Produktionslinienüberwachung zu finden sind [152, 206], weisen bestimmte Einschränkungen bzgl. der Identifikation von Problemen im Prozessablauf auf. Diese Ansätze setzen entweder darauf, Produkte (*i*) am Ende des Ablaufs hinsichtlich Mängel zu analysieren, oder (*ii*) unmittelbar nach der Ausführung einzelner Prozessschritte auf Fehler untersuchen. Wenn Produkte losgelöst vom Ablauf am Ende einer Prozesskette (Ansatz *i*) klassifiziert werden, ermöglicht dies zwar die Aussortierung von mangelhaften Ergebnissen, jedoch liefert es keine Information darüber, an welcher Stelle im Ablauf der Fehler verursacht wurde. Diese Methode ist zwar effektiv, um defekte Produkte zu erkennen, jedoch unzureichend, um die Ursache des Fehlers genau zu bestimmen und den Prozess zu korrigieren. Dagegen ermöglicht die Überwachung der Produktqualität nach jedem einzelnen Schritt im Prozess (Ansatz *ii*) eine genauere Lokalisierung des Fehlers. Allerdings geht mit diesem Ansatz das Problem einher, dass gegenseitige Einflüsse und Abhängigkeiten der Prozessschritte voneinander nicht berücksichtigt werden. Beispielsweise könnte die Qualität eines Produkts direkt nach der Ausführung eines Prozessschritts p_1 als positiv

bewertet werden, während das Produkt nach Ausführung eines nachfolgenden Schritts p_2 als mangelhaft eingestuft wird. Klassische Verfahren identifizieren p_2 als die Ursache für das fehlerhafte Produkt, da der Fehler direkt nach dessen Ausführung auftritt und erst an dieser Stelle auffällt. Allerdings ist der Fehler der Ausführung von p_1 zuzuordnen. Der Grund dafür können relevante Details sein, die im Prozessmodell fehlen. Der Prozessschritt p_2 kann noch unbekannte Anforderungen mit sich bringen, die bereits in vorherigen Prozessschritten zur Sicherung des Prozesses beachtet werden müssen. Die systematische Analyse dieser Anforderungen ist ein entscheidender Schritt. Ebenso wichtig ist die genaue Identifikation der Stelle im Prozess, an der das Problem tatsächlich verursacht wird (p_1) und wo Verbesserungsmaßnahmen ansetzen müssen. Diese Problematik verdeutlicht die Notwendigkeit eines ganzheitlichen Verfahrens, das in gewisser Weise beide Herangehensweisen (Ansätze *i* und *ii*) kombiniert und in der Lage ist, den Ursprung von Fehlern tiefergehend zu analysieren und Fehlerpropagationen aufzudecken. Durch ein Labeling der Ausführungsdaten bzgl. des gesamten Prozesses können in Verbindung mit dem iterativen Konzept derartige Probleme analysiert werden.

Das Ergebnis von Ausführung und Labeling sind Paare der Form $(d(a)_i, l_i)$ pro Prozessmodellausführung $i \in I$, wobei $d(a)_i$ die für a aufgenommenen Daten aus d sind und l das Label entsprechend des Prozesses ist. Die Gesamtheit der gesammelten Daten $V = \{(d(a)_i, l_i) | i \in I\}$ wird in einem geeigneten Speichersystem abgelegt, wie beispielsweise einer Datenbank. Da für den nachfolgenden Analyseschritt eine ausreichende Datenbasis erforderlich ist, wird das Prozessmodell mehrmals ausgeführt und ein entsprechender Datenbestand aufgebaut.

Beispiel: Bei der Herstellung eines Automobils wird die Montage der Feinelektronik in Form eines Videos aufgenommen. Dieses erhält nach Durchlaufen der kompletten Produktionskette ein Label bzgl. der Qualität der Komponente, in der die entsprechende Feinelektronik verbaut ist. In dem hier angeführten Szenario kann das Label im Rahmen von Funktionstests der Komponente bestimmt werden. Durch diese wird beispielsweise festgestellt, dass die Ergebnisse der Tests variieren, d.h. die Komponente ist gelegentlich voll funktionsfähig und in anderen Fällen nur eingeschränkt nutzbar. Alle aufgenommenen Videos werden mit ihrem entsprechenden Label gesammelt und abgespeichert.

3.3.4 ANALYSE

Im Schritt ‚Analyse‘ erfolgt eine Untersuchung der gelabelten Ausführungsdaten V mit dem Ziel, relevante Prozessdetails zu finden, die im Prozessmodell fehlen. Formal werden relevante Prozessdetails in dieser Arbeit in Form einer allgemeinen Regel r definiert, die Bedingungen aufstellt, unter denen sich der Prozess Erfolg bei der Ausführung von

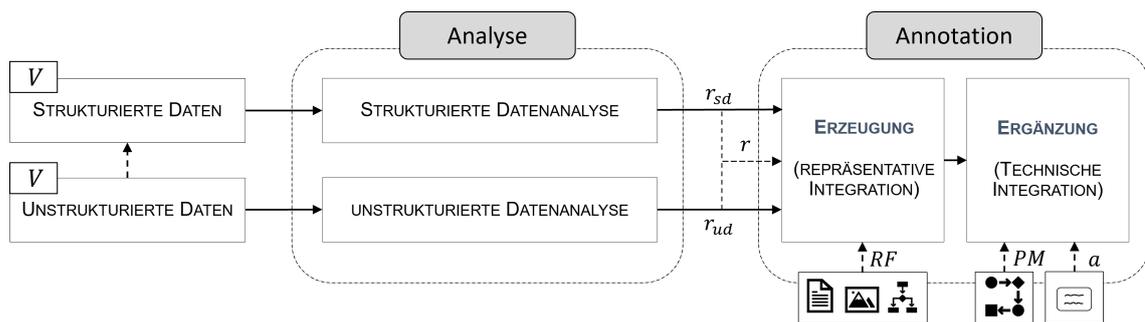


Abbildung 12: Detailansichten des Analyse- und Annotationsschritts, publiziert in [81]. Abhängig von der Struktur der Daten müssen die Schritte angepasst werden.

Aufgabe a erhöht. Dafür wird r im Sinne einer ‚Wenn-Dann‘-Formulierung definiert und entspricht einer mathematischen Implikation $X \Rightarrow Y$. An der Stelle von Y steht dabei immer Prozesserfolg. Variable X beschreibt eine Bedingung, die sich aus relevanten Prozessdetails zusammensetzt. Grundsätzlich kann r beliebige Repräsentationen annehmen, solange der Zusammenhang zwischen relevanten Prozessdetails und Prozesserfolg ableitbar ist. Der Analyseschritt wird durch die Funktion $\phi(V) = r$ beschrieben.

Das Finden von r weist Parallelen zum allgemeinen Klassifikationsproblem auf, insbesondere im Zusammenhang mit der Berechnung einer Entscheidungsgrenze, die Punkte unterschiedlicher Klassen in einem Merkmalsraum voneinander trennt. In dieser Betrachtung entspricht r dem Klassifikator und V den hinsichtlich Prozesserfolg gelabelten Datenpunkten im Merkmalsraum. Ein Beispiel ist in Abschnitt 4.1 illustriert. Die Suche nach einer geeigneten Entscheidungsgrenze kann äußerst komplex sein, vor allem wenn der Merkmalsraum umfangreich ist und Datenpunkte verschiedener Klassen über den gesamten Raum verteilt sind. Diese Aspekte hängen entscheidend davon ab, welche Merkmale der Daten berücksichtigt werden, was wiederum stark von der Struktur der Ausführungsdaten abhängt. Dabei wird typischerweise zwischen zwei Arten von Daten unterschieden [208]: strukturierte Daten und unstrukturierte Daten. Strukturierte Daten sind nach einer bestimmten Struktur formatiert, z.B. in Form einer Tabelle oder relationalen Datenbank. Im Gegensatz dazu werden unstrukturierte Daten in ihrem ursprünglichen Format gespeichert und sind nicht nach einem vordefinierten Schema organisiert. Beispiele hierfür sind Audio-, Text- oder Bilddaten. Um neue Erkenntnisse wie Entscheidungsgrenzen bzw. Regeln aus strukturierten Datensätzen zu gewinnen, kommen insbesondere Techniken aus dem regelbasierten Data Mining zum Einsatz [108, 143]. Für die Analyse unstrukturierter Daten, die komplexere Muster enthalten, werden im Allgemeinen Ansätze mit neuronalen Netzen bevorzugt [11, 212]. In Abhängigkeit von der Struktur des vorliegenden Datensatzes sind somit unterschiedliche Analyseansätze erforderlich um $r = \phi(V)$ zu berechnen (vgl. „Analyse“ in Abbildung 12). Aus dem Ergebnis kann die oben definierte Implika-

tion $X \Rightarrow Y$ für r nicht direkt abgelesen werden, sondern muss je nach Analyseansatz ggf. nachverarbeitet werden. Zur Unterscheidung wird das Ergebnis einer strukturierten Datenanalyse als r_{sd} und das einer unstrukturierten Datenanalyse als r_{ud} bezeichnet. Darüber hinaus ist es je nach Anwendungsbereich auch möglich, unstrukturierte Daten mit verschiedenen Ansätzen in strukturierte Daten umzuwandeln [30, 163, 291]. Der Kern aller Verfahren besteht jedoch darin, eine Reihe von strukturierbaren Informationen oder Attributen aus den unstrukturierten Daten zu extrahieren. Diese Aufgabe wird gemeinsam mit der Entwicklung, Implementierung und Evaluation passender Ansätze für die beiden Strukturtypen in Kapitel 4 detailliert betrachtet.

Beispiel: Im betrachteten Beispielprozess zur Fahrzeugherstellung werden Videodaten, d.h. unstrukturierte Daten aufgenommen. Diese werden mit geeigneten Verfahren analysiert und ein relevantes Prozessdetail extrahiert. Das Detail enthält beispielsweise in Form einer Regel die Information, dass ein bestimmter Teilschritt der Montage erst nach einem anderen durchgeführt werden darf. So darf der Einbau der Sensorik erst nach der Installation bestimmter Versorgungseinheiten erfolgen, da sonst Verkabelungen der Sensoren abgedrückt werden. Diese Information konnte von den MitarbeiterInnen allerdings bisher aus zwei Gründen nicht während der Montage berücksichtigt werden. Zum einen enthält das Prozessmodell keine entsprechende Anweisungen. Zum anderen war diese Information und damit die Ursache der abweichenden Funktionstests unbekannt.

3.3.5 ANNOTATION

Im Allgemeinen beschreibt r einen Term, der Prozessmerkmale mit logischen Operationen verknüpft. Solche Darstellungen sind für Prozessbeteiligte schwer zu lesen, insbesondere bei umfangreichen Regeln, die mehrere Prozessaspekte oder Merkmale berücksichtigen. Aus diesem Grund muss r nachbearbeitet werden, um das enthaltene relevante Prozessdetail lesbar und leicht verständlich in das bestehende Modell zu integrieren. Dies geschieht durch die Verwendung von sog. **Aufgabenannotationen**. Für die Integration von r in PM durch eine Aufgabenannotation sind zwei Teilschritte notwendig (vgl. „Annotation“ in Abbildung 12). Im Teilschritt „Erzeugung“ (Abschnitt 3.3.5.1) wird zunächst die Aufgabenannotation zu r in einem geeigneten Repräsentationsformat RF erstellt. Damit liegt der Schwerpunkt auf der repräsentativen Integration. Anschließend erfolgt die technische Integration der erzeugten Annotation in PM durch Anpassung von a im Teilschritt „Ergänzung“ (Abschnitt 3.3.5.2).

3.3.5.1 ERZEUGUNG

Die Erzeugung einer Aufgabenannotation hängt von (i) der beabsichtigten Darstellung von r in PM ab, d.h. in welchem Repräsentationsformat $f \in RF$ das Detail integriert werden soll und (ii) der aktuellen Form von r , d.h. welche Analysetechnik im vorherigen Schritt bedingt durch die vorliegende Struktur der Ausführungsdaten gewählt worden ist. Die Ergebnisse einer strukturierten (r_{sd}) und einer unstrukturierten Datenanalyse (r_{ud}) erfordern verschiedene Nachverarbeitungsschritte, um eine einheitliche Darstellung von r zu erreichen. Auf Basis dieser wird anschließend eine Aufgabenannotation erzeugt.

In der Menge der Repräsentationsformate RF werden drei Varianten unterschieden. Relevante Prozessdetails können in Form von Aufgabenannotationen **textuell**, **bildlich** oder **diagrammatisch** dargestellt werden. Dabei besteht das Hauptziel darin, ein Repräsentationsformat zu wählen, das alle in r enthaltenen Informationen abbilden kann und dabei die Lesbarkeit des Modells bewahrt. In der vorliegenden Forschungsarbeit wird diese Herausforderung durch die Untersuchung der **intuitiven Benutzbarkeit** verschiedener Repräsentationsformate für Aufgabenannotationen gelöst. Kapitel 5 widmet sich vorwiegend dieser Thematik, da dieser Aspekt einen eigenständigen Beitrag darstellt. Darunter beleuchtet Abschnitt 5.4.1 Möglichkeiten zur Umwandlung von r in die gewählte Repräsentationsart. Ergänzend werden nach der Analyse erforderliche Schritte erörtert, um von unstrukturierten sowie strukturierten Analyseansätzen zu einer einheitlichen Darstellung von r zu gelangen.

3.3.5.2 ERGÄNZUNG

Anschließend wird die erstellte Aufgabenannotation in PM durch Erweiterung von a integriert. Dies kann je nach Repräsentationsformat auf verschiedene Weise geschehen. Dabei ist grundsätzlich für alle Repräsentationsformate eine einfache Integration in Form eines Anhangs möglich, wie in [282] vorgeschlagen. In diesem Fall wird jedes Repräsentationsformat als ein Medium betrachtet, das an eine Aufgabe angehängt wird (Multimedia-Annotationen) und während der Prozessausführung zur Verfügung steht. Sie können von AnwenderInnen direkt genutzt werden, ohne dass der implementierte Geschäftsprozess geändert werden muss. Erfordert die in einer Annotation enthaltene Information die Zerlegung einer Aufgabe in Teilschritte, kann dagegen auch eine strukturelle Anpassung des Prozessmodells gewinnbringend sein. Verschiedene Möglichkeiten zur Integration von Aufgabenannotationen werden in Abschnitt 5.4.2 erläutert.

Das Ergebnis des Annotationsschritts ist ein verbessertes Prozessmodell PM^* . Es entspricht dem ursprünglichen Modell PM , jedoch ist a um relevante Prozessdetails durch die entsprechende Annotation angereichert. Die Modifikation von a wird durch $(a, r)_f$

beschrieben. Anschließend wird, wie in Abschnitt 3.2 erläutert, die Validierungsphase angestoßen, um die Veränderungen in PM^* zu überprüfen.

Beispiel: Der Prozessschritt zur Montage der Feinelektronik wird diagrammatisch um die analysierte relevante Information erweitert. Sie sieht eine Reihenfolge für den Einbau bestimmter Teile vor. Dafür wird die im Prozessmodell nicht weiter spezifizierte Aufgabe zur Montage der Feinelektronik in mehrere Aufgaben und somit in Teilschritte zerlegt. Diese werden so angeordnet, dass der Einbau der Sensoren nach der Versorgungseinheiten erfolgt, wodurch der Erfolg zukünftiger Ausführungen sichergestellt wird.

3.4 ANNAHMEN UND RAHMENBEDINGUNGEN ZUR ANWENDUNG

Für die Anwendung des entwickelten Gesamtkonzepts und insbesondere der Verbesserungsphase gelten bestimmte Bedingungen, die erfüllt sein müssen.

Datenquantität: Für die Effektivität des Analyseschritts in der Verbesserungsphase ist eine ausreichende Menge gelabelter Daten notwendig. Trotz der Erfassung von Ausführungsdaten im Rahmen des täglichen Betriebs von Organisationen kann diese Anforderung nicht immer erfüllt werden. Insbesondere kleine und mittelständische Unternehmen produzieren im Vergleich zu industriellen Großbetrieben in der Regel kleinere Mengen von Produkten, führen Prozesse weniger häufig durch und sammeln daher weniger Ausführungsdaten. Darüber hinaus zeigt sich ein Paradigmenwechsel von traditioneller Massenproduktion hin zur Kleinserienproduktion und der Fertigung individualisierter Produkte [226]. Dieser Wandel manifestiert sich in einer Zunahme der Prozessvarianz und einer Abnahme der Ausführung des selben Prozesses.

Datenqualität und Trennbarkeit: Um r zu finden, muss eine eindeutige Entscheidungsgrenze im Merkmalsraum der Daten berechnet werden, die negativ gelabelte Einträge von positiv gelabelten trennt. Dies setzt die Wahl eines geeigneten Merkmalsraum voraus. Einerseits muss entschieden werden, welche Aspekte eines Prozesses durch die Datenerfassung abgebildet werden. Andererseits muss festgelegt werden, welche Merkmale innerhalb der Daten betrachtet werden sollen. Diese Entscheidungen gestalten sich als besonders anspruchsvoll, wenn die relevanten Prozessdetails unbekannt sind. Für die Bestimmung einer Entscheidungsgrenze gilt weiter, dass der Merkmalsraum durch die aufgenommenen, gelabelten Daten möglichst vollständig exploriert sein sollte. Dieser Aspekt ist ebenfalls an die Anforderung der Datenquantität geknüpft.

Optimierungsunabhängigkeit: Damit die vom Gesamtkonzept vorgesehene inkrementelle Verbesserung eines Prozessmodells möglich ist, müssen die in der Verbesserungsphase betrachteten Aufgaben **unabhängig voneinander** optimiert werden können. Dafür wird angenommen, dass ein globales Kriterium existiert, mit dem Prozesserfolg erreicht werden kann. Dieses definiert für die Merkmale einer Aufgabe erlaubte Wertebereiche. Die Aufgaben gelten dann als unabhängig optimierbar, wenn die erlaubten Wertebereiche einer Aufgabe nicht von den Wertebereichen einer anderen Aufgaben abhängen. Dabei dürfen innerhalb einer Aufgabe die zulässigen Wertebereiche durchaus voneinander abhängen. Betrachtet man beispielsweise zwei Aufgaben A und B sowie je zwei Wertebereiche für die Merkmale dieser Aufgaben mit A_{W1}, A_{W2} für Aufgabe A und B_{W1}, B_{W2} für Aufgabe B . Dann gelten z.B. Aufgaben A und B als nicht unabhängig optimierbar, falls gleichzeitig ‚ A_{W1} und B_{W2} ‘ oder ‚ A_{W2} und B_{W1} ‘ erlaubt sind, aber nicht ‚ A_{W1} und B_{W1} ‘ oder ‚ A_{W2} und B_{W2} ‘. Bei einem Verfahren, das für jede Aufgabe Wertebereiche ermitteln will, die unabhängig voneinander erlaubt sind, kann dann nur eine der Kombinationen gefunden werden. Dies bedeutet auch, dass die Reihenfolge, in der die Aufgaben optimiert werden, Einfluss auf das Ergebnis haben kann. Um diese Problemstellung zu adressieren können mehrere Aufgaben gleichzeitig betrachtet werden. Dies erfordert komplexere Analysemethoden und wird mit dem im Rahmen dieser Arbeit entwickelten Gesamtkonzept nicht abgedeckt. Gilt dagegen die Annahme der Optimierungsunabhängigkeit, ist die Reihenfolge, in der die Aufgaben optimiert werden, irrelevant. Diese Eigenschaft ermöglicht damit die in Abschnitt 3.2 beschriebene inkrementelle Vorgehensweise des Gesamtkonzepts zur Verbesserung von Prozessmodellen.

3.5 DATENTYPEN UND SENSORIK

In Prozessumgebungen gibt es verschiedene Datenquellen, die für die Analyse relevanter Prozessdetails genutzt werden können. Im Allgemeinen kann eine Datenquelle als ein System definiert werden, das (digitale) Daten enthält und bereitstellt [136]. Datenquellen können dabei durch den Einsatz verschiedener Technik entstehen. Für diese Arbeit wird in Prozessumgebungen zwischen zwei Datenlieferanten unterschieden: (i) Sensoren, die physikalische Phänomene in der Umgebung aufzeichnen und (ii) Software- oder digitale Werkzeuge, die im Kontext der Ausführungsumgebungen verwendet werden. Beide können Ausführungsdaten von Prozessumgebungen aufnehmen, unterscheiden sich dabei aber stark im Grad der Abstraktion und dem Einbezug von Kontextwissen. Sensoren kommen zur Messung verschiedener Parameter zum Einsatz und nehmen Umgebungsdaten direkt und unverarbeitet auf. Dagegen sind Systeme zur Koordination von Arbeitsabläufen

und Ausführung von Modellen prozessbezogene Software, die beispielsweise der Erzeugung von Ereignisprotokollen dient. In modernen Prozessumgebungen, die Techniken aus dem Bereich IoT (engl. *Internet of Things*) verwenden, werden Sensordaten mit prozessbezogener Software in Beziehung gebracht, um beispielsweise Aktivitäten zu analysieren [62]. Neben ihrem klassischen Einsatz zur Überwachung von Prozessen dienen Sensoren somit auch zur Extraktion von Prozesswissen und sind damit für die Prozessverbesserung eine wichtige Technologie. Dies betrifft auch die Analyse relevanter Prozessdetails. Dabei wird im Folgenden die Eignung unterschiedlicher Sensorik und daraus resultierender Sensordaten zur Analyse der verschiedenen Typen relevanter Prozessdetails (Abschnitt 1.2.3) betrachtet [81]. Der Fokus liegt auf Sensoren, die häufig zur Überwachung von Prozessausführungen in Produktionsanlagen verwendet werden [241].

Optische Sensoren: Systeme, die in der Lage sind, Licht zu erfassen und in ein digitales Signal umzuwandeln, werden als optische Sensoren bezeichnet. Die häufigsten Geräte, die diese Technologie verwenden, sind Kamerasysteme. Die Ausgabe sind Bilder oder Bildsequenzen, d.h. Videos. Kamerasysteme werden in verschiedenen Bereichen zur Prozessüberwachung oder Qualitätskontrolle eingesetzt [47, 288]. Sie sind kostengünstig, erfordern keine zusätzliche Hardware und sind leicht in Prozessumgebungen integrierbar. Außerdem erweist sich die Nutzung von Bilddaten und ihre Analyse mittels sog. *Image Mining*-Techniken² als vorteilhaft für alle Phasen des Prozesslebenszyklus [236].

Bilddaten, die in Prozessumgebungen aufgenommen werden, enthalten umfangreiche Prozessinformationen und sind für die Analyse aller Arten relevanter Prozessdetails geeignet. Während der Ausführung einer Aufgabe aufgenommene Bilder können datenorientierte, organisatorische und operationale relevante Prozessdetails enthalten. Beispielsweise kann ein Bild, das den Zustand der Arbeitsfläche nach einer Aufgabenausführung zeigt, relevante Informationen über die Position oder Art von Objekten (datenorientiert) enthalten. Ähnliche Aufnahmen (evtl. aus anderen Perspektiven) können beteiligte Akteure (organisatorisch) oder Werkzeuge (operational) zeigen, die am Prozess teilnehmen.

Für die Analyse funktionaler und verhaltensorientierter relevanter Prozessdetails reicht jedoch ein einzelnes Bild nicht aus. Für diesen Zweck können Videos verwendet werden, welche die gesamte Aufgabenausführung zeigen. Aus diesen können noch nicht modellierte Teilschritte (funktional) oder relevante Ausführungsreihenfolgen (verhaltensorientiert) extrahiert werden. Daneben eignen sich Videodaten auch für die Analyse anderer Typen relevanter Details, indem zum Beispiel Techniken zur Verfolgung von Akteuren (organisatorisch), Werkzeugen (operational) oder Objekten (datenorientiert) zum Einsatz kommen, die ihr Auftreten in bestimmten Aktivitäten identifizieren.

² ‚Image Mining‘ umfasst eine Gruppe von Ansätzen zur Extraktion von Wissen aus Bilddaten.

Für Bilddaten ist anzumerken, dass nur Details, die durch Bilddaten ausgedrückt werden können, erkennbar sind. Tiefeninformationen oder andere Informationen wie beispielsweise die Raumtemperatur können nicht aus einem 2D-Bild abgeleitet werden.

Elektromagnetische Sensoren: Elektromagnetische Wellen werden als Mechanismus genutzt, um Informationen aus der Umgebung mithilfe elektromagnetischer Sensoren zu erfassen. Darunter ist eine häufig verwendete Technologie die Funkfrequenz-Identifikation (engl. *Radio Frequency Identification* (RFID)), welche eine Identifikation und Verfolgung von Objekten mit Radiowellen ermöglicht. RFID-Etiketten (engl. *RFID tags*) übertragen Daten an ein Lesegerät, das die Informationen an ein RFID-Computerprogramm übermittelt. Sie werden in vielen Fertigungsumgebungen zur Aktivitätsverfolgung eingesetzt [252, 258]. Sie können verwendet werden, um relevante Prozessdetails zu analysieren, indem beispielsweise Montageschritte (funktional) und ihre Reihenfolge (verhaltensorientiert) erfasst werden. Darüber hinaus können sie an Kleidung und Arbeitsmittel angebracht werden, um zu erkennen, welche MitarbeiterInnen (organisatorisch) welche Werkzeuge (operational) für eine bestimmte Aufgabe verwenden. Andere Gegenstände im Arbeitsraum können ebenfalls mit RFID-Etiketten ausgestattet werden, um weitere objektbezogene Informationen wie ihre Positionen zu identifizieren (datenorientiert). Ein Vorteil elektromagnetischer Wellen ist, dass sie Objekte durchdringen. Dementsprechend ist keine direkte Sichtverbindung erforderlich, um Objekte mit RFID zu identifizieren. Im Gegensatz dazu kann die Kommunikation zwischen Sender und Empfänger durch Flüssigkeiten oder Metall gestört werden, was abhängig von der Domäne ein erhebliches Problem darstellen kann.

Akustik-, Temperatur-, Feuchtigkeits-, Kraftsensoren: Alle Sensoren, die bestimmte physikalische Größen aufzeichnen, werden in dieser Kategorie zusammengefasst. Derartige Sensordaten können hauptsächlich verwendet werden, um fehlende datenorientierte relevante Prozessdetails zu analysieren. Während der Prozessausführung durch solche Sensoren erfassten Daten können beispielsweise die Information enthalten, dass eine bestimmte Temperatur für den Erfolg eines Prozesses relevant ist.

Obwohl keine weiteren Informationen im Zusammenhang mit den anderen Typen relevanter Prozessdetails aus solchen Sensordaten extrahiert werden können, ist es möglich, Hinweise auf ihr Fehlen im Modell abzuleiten. Treten beispielsweise messbare aber unerwartete Temperaturschwankungen innerhalb verschiedener Ausführungsvorgänge auf, ist anzunehmen, dass MitarbeiterInnen den Prozess unterschiedlich ausführen. Ursache können zu abstrakte Prozessmodelle mit unzureichendem Informationsgehalt sein. So sind beispielsweise Teilschritte einer Aufgabe nicht modelliert (funktional), die darüber hinaus

in einer bestimmten Reihenfolge auszuführen sind (verhaltensbasiert). In anderen Fällen könnte auch die Verwendung eines bestimmten Werkzeugs (operational) die Temperaturveränderung verursachen. Diese Hypothesen erfordern jedoch eine Validierung mit realen Prozessdaten und Fachwissen.

3.6 ZUSAMMENFASSUNG

In diesem Kapitel wird das entwickelte Gesamtkonzept zur Verbesserung von Prozessmodellen durch relevante Prozessdetails erläutert. Seine Architektur orientiert sich am Prozesslebenszyklus und definiert die drei Phasen Beobachtung, Verbesserung und Validierung. Darunter beschreiben die Verbesserungs- und Validierungsphase gemeinsam einen iterativen Ansatz zur sukzessiven Verbesserung von Prozessmodellen.

Durch die im Konzept definierte Vorgehensweise werden abstrakte Aufgabenbeschreibungen in Prozessmodellen spezifiziert, wobei ausschließlich essenzielle Informationen berücksichtigt werden. Diese werden intuitiv verständlich durch die Verwendung von Aufgabenannotationen in Modelle integriert. Auf diese Weise wird die Lesbarkeit der Prozessmodelle bewahrt, als auch alle notwendigen Informationen für eine erfolgreiche Prozessausführung bereitgestellt. Damit erfüllt das Gesamtkonzept innovativ diese gleichzeitig geltenden Anforderungen an effektive Prozessmodelle und beantwortet die zentrale Forschungsfrage der vorliegenden Arbeit, d.h. wie Prozessmodelle durch relevante Prozessdetails verbessert werden können.

Die Analyse relevanter Prozessdetails erfolgt auf Grundlage gelabelter Ausführungsdaten, die durch verschiedene Datenquellen in der Prozessumgebung erfasst werden. Die Betrachtung externer Informationsquellen dient dabei als fundamentaler Aspekt des Konzepts und prägt dessen innovativen Charakter. Eine derartige Vorgehensweise ist die Voraussetzung zur Extraktion von neuem bzw. noch unbekanntem, aber relevantem Prozesswissen. Dabei wird sowohl die Analyse von strukturierten als auch unstrukturierten Daten unterstützt. In diesem Zusammenhang wird die Eignung verschiedener Sensoren und der von ihnen erfassten Ausführungsdaten zur Analyse unterschiedlicher Typen relevanter Prozessdetails diskutiert. Daraus wird ersichtlich, dass der Einsatz bestimmter Sensoren gewisse Einschränkungen mit sich bringen kann, jedoch alle dadurch aufgenommenen Daten potenziell wertvolle Erkenntnisse über Prozesse enthalten können. Das Gesamtkonzept steht im Mittelpunkt der vorliegenden Arbeit und stellt den Ausgangspunkt der nachfolgenden Kapitel dar.

4 | UMSETZUNG DES ANALYSESCHRITTS AM BEISPIEL VON BILDDATEN

Dieses Kapitel umfasst eine detaillierte Darstellung der Umsetzung des Analyseschritts aus der Verbesserungsphase (vgl. Abbildung 11) anhand von Bilddaten. Dafür wird zunächst die grundlegende Idee des Schritts an einem vereinfachten Beispiel veranschaulicht (Abschnitt 4.1). Anschließend wird die Eignung von Bildern aus Prozessumgebungen als effektive Datenquelle für die Umsetzung diskutiert (Abschnitt 4.2). Basierend auf einem realen Prozess aus dem herstellenden Gewerbe wird ein Experimentaufbau mit zwei verschiedenen Szenarien entworfen (Abschnitt 4.3). Dazu werden Bilddaten generiert und anhand von zwei entwickelten Analysemethoden gezeigt, wie datenorientierte relevante Prozessdetails aus derartigen Datensätzen extrahiert werden können. Die Methoden werden prototypisch implementiert und ausgiebig evaluiert. Zum einen wird dafür eine Technik aus dem Bereich der erklärbaren künstlichen Intelligenz (Abschnitt 4.4) und zum anderen ein regelbasierter Ansatz aus dem Bereich des Data Mining (Abschnitt 4.5) verwendet. Die Anwendung der Methoden beantwortet Forschungsfrage 1 aus Abschnitt 1.3, d.h. wie relevante Prozessdetails identifiziert und analysiert werden können. Dabei wird illustriert, wie gelabelte Daten genutzt werden können, um relevante Prozessinformationen aus komplexen Datenbeständen herauszufiltern. Dieses Vorgehen adressiert die ersten beiden Teilforschungsfragen und erläutert somit wie noch unbekannte Prozessdetails entdeckt und von irrelevanten Details unterschieden werden können. Die Anwendung der Methoden in den Experimenten unterstützt die Beantwortung der dritten Teilfrage, d.h. welche Typen relevanter Prozessdetails analysiert werden können. Die Methoden werden bzgl. ihrer Anforderungen und Ergebnisse miteinander verglichen und die damit verbundenen Aspekte im Kontext realer Prozessumgebungen diskutiert (Abschnitt 4.6).

Die Experimente und Ergebnisse sind zum größten Teil bereits in [82, 85] veröffentlicht. Die dort beschriebenen Inhalte werden in diesem Kapitel erweitert, indem sie in den Gesamtkontext der Arbeit eingebettet und ausführlich betrachtet werden. Dabei werden detaillierte Hintergrundinformationen und Beschreibungen der entwickelten Methoden ergänzt sowie die Methoden auf Basis der Experimentergebnisse miteinander verglichen.

4.1 MOTIVIERENDES BEISPIEL UND GRUNDIDEE

Wie in Abschnitt 3.3.3 diskutiert, genügt es nicht, lediglich fehlerhafte Prozessergebnisse zu erkennen. Es reicht auch nicht aus, Vorhersagen darüber zu treffen, ob eine Prozessausführung scheitern wird. Die Komplexität des Analyseschritts besteht vielmehr darin, die Frage zu beantworten, **warum** ein Fehler aufgetreten ist und insbesondere wie er sich lösen lässt. Das bedeutet, es muss ermittelt werden, welcher spezifische Schritt in einem Prozessmodell und was bei seiner Ausführung für einen Fehler verantwortlich ist. Diese Herausforderung ist besonders anspruchsvoll, wenn selbst erfahrene ProzessexpertInnen ad hoc keine Hinweise darauf geben können, wo der Ursprung des Problems liegen könnte. Um diesen Schritt und die damit verbundenen Anforderungen erfolgreich umzusetzen, ist es erforderlich, die Zusammenhänge zwischen dem Erfolg (oder dem Scheitern) eines Prozesses und Merkmalen der Ausführungsdaten zu identifizieren. Es muss ermittelt werden, ob die Anwesenheit bestimmter Merkmale signifikant mit dem Erfolg eines Prozesses korreliert. Diese identifizierten Merkmale fungieren als Ursache für den Prozesserfolg. Sie repräsentieren zusammen mit ihren Ausprägungen somit relevante Prozessinformationen, die während der Ausführung eines Modells berücksichtigt werden müssen, um unzureichende Prozessergebnisse in zukünftigen Ausführungen zu vermeiden.

In dieser Arbeit wird diese Problemstellung auf ein **Klassifizierungsproblem** im Merkmalsraum der gesammelten und gelabelten Ausführungsdaten zurückgeführt. Dabei geht es im Wesentlichen um das Finden einer mathematischen Funktion, die Merkmalsausprägungen, die mit Prozesserfolg korrelieren, von denen, die zu Prozessfehlschlag führen, trennt. Diese Funktion wird anschließend genutzt, um eine Regel aufzustellen, die Kriterien zum Erzielen von Prozesserfolg enthält. Die daraus ableitbaren Beschreibungen der auftretenden Merkmale samt Ausprägungen entsprechen den relevanten Prozessdetails. Zur Erläuterung wird ein abstraktes Beispiel betrachtet, das an einen realen Prozess aus der Elektroindustrie angelehnt ist. Der Prozess des *Conformal Coating* bezeichnet das Auftragen einer Schutzschicht auf elektronische Baugruppen, wie beispielsweise Platinen. Dafür wird fluoreszierender Epoxidharzklebstoff aufgetragen und mit ultraviolettem Licht ausgehärtet. In dem Beispiel wird angenommen, dass den Teilnehmenden des Prozesses verschiedene Klebstoffvarianten zur Verfügung stehen, welche sich in Bezug auf ihren Gehalt an Epoxidharz (EP-Harz) unterscheiden. Im Verlauf der Prozessausführung werden präzise Aufzeichnungen über zwei Merkmale des Schritts geführt. Zum einen über die Menge des verwendeten Klebstoffs und zum anderen über die jeweilige Art des Klebers, einschließlich des darin enthaltenen Anteils an EP-Harz. Im Anschluss daran erfolgt eine eingehende Untersuchung und Beurteilung der aufgetragenen Schutzschicht auf der Platine mittels verschiedener Tests. Die tabellarische Darstellung in Tabelle 4.1

# Ausführung	Stoffmenge	Anteil EP-Harz	Bewertung Ergebnis
A1	150 mg	5 %	unzureichend
A2	350 mg	7 %	erfolgreich
A3	380 mg	11 %	erfolgreich
A4	400 mg	17 %	erfolgreich
A5	55 mg	19 %	unzureichend
...
A25	450 mg	85%	erfolgreich

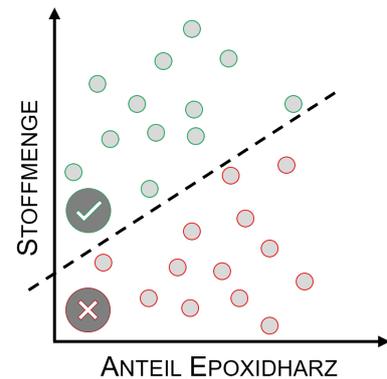


Tabelle 4.1: Gesammelte Beispieldaten aus dem Beschichtungsprozess von Platinen mit EP-Harz. Abbildung 13: Darstellung des Merkmalsraums der Daten und Trennung.

illustriert beispielhaft, wie die erfassten Daten in einem derartigen Prozess aussehen können. Im Rahmen des Analyseprozesses wird anschließend die **Trennfunktion** berechnet. Abbildung 13 veranschaulicht diesen Schritt, indem sie den Merkmalsraum der Daten (Stoffmenge, Anteil EP-Harz und Bewertung) und die ermittelte Trennfunktion (gestrichelt) zwischen erfolgreichen Prozessergebnissen (Grün) und unzureichenden Prozessergebnissen (Rot) darstellt. An der Trennfunktion ist ein Zusammenhang zwischen dem Anteil des EP-Harz und der Menge des Klebstoffs zu erkennen. Daraus ist das relevante Prozessdetail abzuleiten, welches die Information enthält, dass eine Mindestmenge an Klebstoff erforderlich ist, um den Erfolg des Prozesses sicherzustellen. An dieser Stelle sei angemerkt, dass dieses Beispiel abstrakt gehalten ist und einige Aspekte stark vereinfacht sind. Hierzu gehören insbesondere die Betrachtung der Struktur der gesammelten Ausführungsdaten und des Merkmalsraums, aus denen sich spezifische Anforderungen an das Analyseverfahren ergeben. Diese Punkte werden in den nachfolgenden Abschnitten anhand komplexerer Aufbauten im Kontext von Bilddaten betrachtet, die aus verschiedenen Gründen eine gute Grundlage für die Analyse relevanter Prozessdetails bieten.

4.2 VORTEILE VON BILDDATEN

Für die Evaluation der implementierten Methoden fokussiert sich diese Arbeit auf die Verwendung von **Bilddaten**, d.h. Aufnahmen aus realen Prozessumgebungen. Sie eignen sich als Analysequelle zur Extraktion relevanter Prozessdetails und bieten eine Vielzahl von Vorteilen, die in Hinblick auf verschiedene Aspekte betrachtet werden können.

Kosteneffiziente Sensoren: Bilddaten werden durch Kamerasysteme erfasst, die im Vergleich zu anderen Sensorsystemen eine kostengünstige Lösung darstellen [176]. Diese

ökonomische Zugänglichkeit erleichtert ihre weitreichende Anwendung in diversen Branchen und Prozessumgebungen.

Integration in Prozessumgebungen: Zum einen sind Kamerasysteme bereits in vielen Prozessumgebungen integriert und kommen insbesondere zur Prozessüberwachung zum Einsatz [47, 288]. Die Nutzung von Bilddaten erfordert daher keine zusätzliche sensorische Implementierung. Zum anderen beeinträchtigen Kamerasysteme den täglichen Betrieb eines Unternehmens nicht und interferieren nicht mit spezifischen Arbeitsschritten. Im Gegensatz zu anderen Technologien wie elektromagnetischen Sensoren, die in bestimmten Prozessumgebungen aufgrund ihrer Materialeigenschaften nicht anwendbar sind [250], sind Kamerasysteme eine robuste Lösung zur Datenerfassung.

Analyse unstrukturierter Daten: Unternehmen sehen sich mit einem erheblichen Anteil unstrukturierter Daten konfrontiert (80 bis 90%), deren Volumen im Vergleich zu strukturierten Daten schneller zunimmt [61, 71, 165]. Die Menge unstrukturierter Daten umfasst unter anderem Bilddaten, die typischerweise nicht ausreichend analysiert werden, da sich etablierte Verfahren auf strukturierte Daten konzentrieren [145]. Die Entwicklung eines Ansatzes, der auch die Analyse von Bilddaten unterstützt, ermöglicht eine umfassendere Auswertung gesammelter Prozessdaten, die zu neuen Erkenntnissen und Optimierungspotenzialen führt.

Unterstützung des Prozesslebenszyklus: Bilddaten sind vielseitig einsetzbar und unterstützen sämtliche Phasen des Prozesslebenszyklus. Von der Prozessmodellierung über die Implementierung bis hin zur Überwachung und Verbesserung bieten Bilddaten wertvolle Einblicke, um den gesamten Prozess effektiver und effizienter zu gestalten [236].

Hoher Informationsgehalt von Bildern: Bilder haben einen hohen Informationsgehalt und enthalten implizite Informationen [293]. Diese Eigenschaft ist im Rahmen der Problemstellung dieser Arbeit besonders wertvoll. So können aus Bilddaten durch die Verwendung geeigneter Analysemethoden verborgene Muster erkannt werden, was für die Identifikation von relevanten, aber noch unbekanntem Prozessdetails entscheidend ist.

4.3 EXPERIMENTAUFBAU

Zur Evaluation der implementierten Ansätze, die in den nachfolgenden Abschnitten 4.4 und 4.5 detailliert erläutert werden, wird ein Versuchskonzept entwickelt. Dafür dienen spezifische Szenarien aus dem Metallspritzgussprozess als Grundlage für den experimentellen Rahmen. Dieser Prozess beschreibt die Durchführung eines konkreten und realen

Verfahrens aus der Fertigungsindustrie. Er umfasst praktische Problemstellungen, für welche die Analyse relevanter Prozessdetails einen möglichen Lösungsansatz darstellt.

4.3.1 BEISPIELPROZESS METALLSPRITZGUSSVERFAHREN

Das **Metallspritzgussverfahren** oder auch Metallpulverspritzgussverfahren (engl. *metal injection molding*) beschreibt einen typischen Prozess aus dem Fertigungsbereich. Er ist zur Herstellung von metallischen Bauteilen in komplexen Formen entwickelt worden, wie beispielsweise Implantate, Maschinenteile oder chirurgische Werkzeuge. Dafür wird zunächst Metallpulver und Bindemittel mit Hilfe eines Schnellmischers, einem sog. *High Shear Mixer*, vermischt und granuliert. Diese Mischung wird als *Feedstock* bezeichnet und entspricht einer homogene Masse, die durch das anschließende Spritzgießen in einer bestimmten Form verfestigt wird. Danach wird die ‚Entbinderung‘ durchgeführt, die abhängig vom Feedstock entweder thermisch oder mit Hilfe eines Lösemittels erfolgt. Abschließend wird durch ‚Sinterung‘ das Produkt in eine Festkörperstruktur umgewandelt, wodurch die endgültigen Materialeigenschaften bzgl. Dichte und Genauigkeit erreicht werden. Dadurch entsteht das finale Produkt, das je nach Anwendungsgebiet und Anforderungen noch optional einer Reihe von Nachverarbeitungsschritten (z.B. Reinigung) unterzogen werden kann. Metallpulverspritzgießen eignet sich hervorragend für die Serienfertigung präziser Teile mit komplexen Geometrien und feinen Details [221]. Der gesamte Prozess ist in Abbildung 14 dargestellt.

Die Ausführung des Prozesses umfasst einige manuelle Schritte. So werden beispielsweise die sog. ‚Grünlinge‘, die das Ergebnis des Spritzgusschritts sind, auf entsprechenden Chargenträgern platziert. Diese werden in einen Entbinderofen eingesetzt, um den

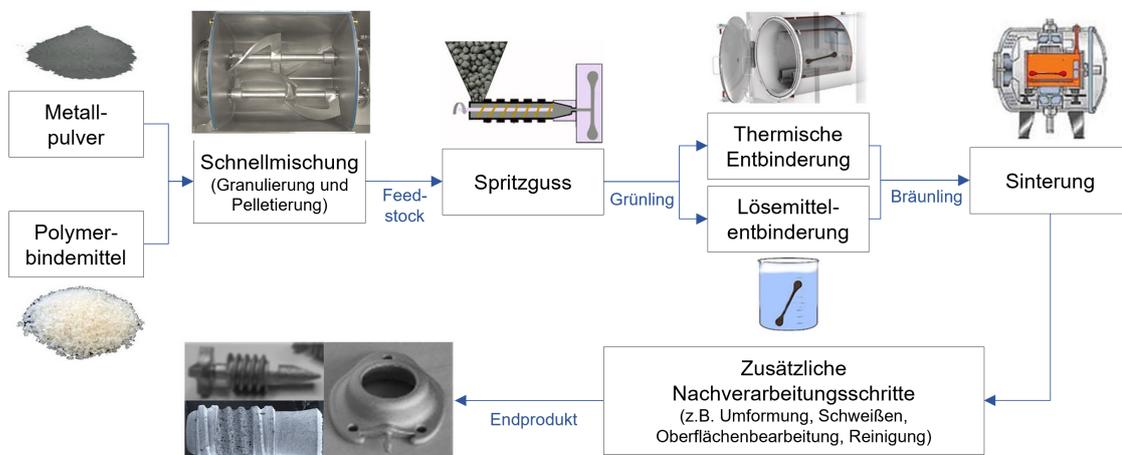


Abbildung 14: Ablauf des Metallspritzgussverfahrens nach [63]. Die einzelnen Schritte sind ins Deutsche übersetzt.



Abbildung 15: Manuelle Bestückung einer Platte mit Werkstücken (links), die anschließend in einen Sinterofen eingesetzt wird (rechts) [219].

größten Teil des enthaltenen Bindemittels thermisch zu entfernen. Die so entstehenden ‚Bräunlinge‘ werden anschließend für den Sinterungsschritt auf dafür vorgesehene Platten mit bestimmten Materialeigenschaften platziert. Die jeweiligen Bestückungsschritte der Platten, die anschließend in die Öfen geschoben werden, erfolgen dabei hauptsächlich händisch durch ArbeiterInnen. Abbildung 15 zeigt die manuelle Ausführung dieser Aufgaben in einer realen Prozessumgebung. Dabei sind die gezeigten Szenen im Rahmen einer Ausführung des Metallextrusionsprozesses entstanden. Beide Prozesse, Metallspritzguss und -extrusion, folgen dem gleichen grundlegenden Ablauf, wobei beim Letzteren der Grünling nicht spritzgegossen, sondern beispielsweise durch einen 3D-Drucker extrudiert wird [219]. Die restlichen Schritte und damit auch die Platzierung der Werkstücke bleibt gleich, weshalb die Prozesse in dieser Hinsicht verallgemeinerbar sind.

Für eine erfolgreiche Ausführung des Prozesses müssen Sinteröfen spezifische Anforderungen erfüllen. Eine solche ist die Aufrechterhaltung einer konstanten Temperatur mit gleichmäßiger Wärmeverteilung [21, 193, 232]. Ist diese Bedingung nicht erfüllt, können (zeitweise) heißere und kühlere Regionen innerhalb des Ofens entstehen. Reicht die Temperatur nicht aus, werden die Oberflächenpartikel der Grünlinge nicht vollständig miteinander verschmolzen. Dies führt zu fehlerhaften Produkten mit geringer Dichte, falschen Größen, inakzeptablen Blasen oder sogar Rissen [129]. Folglich müssen längere Zykluszeiten eingeplant werden, um eine wirksame Verdichtung selbst von voluminösen Teilen zu gewährleisten. Diese verlängerten Zykluszeiten erhöhen jedoch nicht nur die Herstellungskosten, sondern können sich auch negativ auf die Qualität kleinerer Werkstücke auswirken. Effizienter ist dagegen die gezielte Platzierung der größeren oder voluminöseren Komponenten in den heißeren Regionen des Ofens. Die Position eines Werkstücks auf der Platte hat somit einen direkten Einfluss auf die Qualität des Endprodukts.

Da in der Regel Charakteristika, wie beispielsweise die Temperaturverteilung innerhalb eines Sinterofens, unbekannt sind, ist ihre Berücksichtigung während der Prozessausführung und -modellierung schwer realisierbar. Daher enthält das zugrunde liegende Pro-

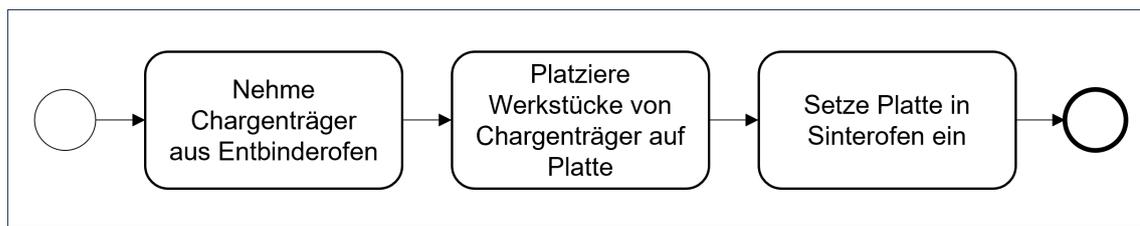


Abbildung 16: BPMN-Modell eines Ausschnitts des Metallspritzgussprozesses.

zessmodell lediglich die Anweisung, Werkstücke auf einer Platte zu platzieren. Genauere Anweisungen zu den konkreten Positionen der Objekte sind in der Aufgabenbeschreibung nicht enthalten. In der Konsequenz beobachten ProzessexpertInnen abweichende Prozessergebnisse, obwohl stets dasselbe Prozessmodell ausgeführt wird (vgl. ‚Beobachtungsphase‘ in Abschnitt 3.2). Abbildung 16 zeigt einen Ausschnitt eines möglichen BPMN-Modells zur Beschreibung der vorbereitenden Arbeitsschritte für die Sinterung. Die beiden Kreise beschreiben den Einstiegspunkt (engl. *start event*) und das Ende des Prozesses (engl. *end event*). Die Aufgaben sind durch abgerundete Vierecke dargestellt, deren Ausführungsreihenfolge durch gerichtete Pfeile vorgegeben sind. Das in dieser Arbeit entwickelte Gesamtkonzept ermöglicht die Ergänzung des Prozessmodells um konkrete Platzierungsanweisungen der Objekte. Derartige Informationen zu Werkstücken, die für den Erfolg eines Prozesses von Bedeutung sind, entsprechen **datenorientierten relevanten Prozessdetails**. Bei der Vorstellung der Implementierungsansätze in den Abschnitten 4.4.3 und 4.5.3 wird prototypisch anhand Platzierungsszenarien gezeigt, wie solche Details aus Bilddaten extrahiert werden können.

4.3.2 SZENARIEN UND EXPERIMENTELLER RAHMEN

Zur Evaluation der Implementierungen des Analyseschritts werden zwei Szenarien entworfen, die sich an der im vorherigen Abschnitt beschriebenen Problemstellung innerhalb des Metallspritzgussprozesses orientieren. Insbesondere derartige Fertigungsprozesse profitieren von Ansätzen, die in der Lage sind, Abweichungen in Ausführungen zu erklären. Im Kontext von Bilddaten gilt dieser Aspekt als noch offene Forschungslücke [227]. Die auf den Szenarien aufbauenden Experimente demonstrieren, wie die Analyse relevanter Prozessdetails diese Herausforderung adressiert. Dabei liegt der Fokus auf dem Schritt der Platzierung von Bräunlingen auf einer Platte. Dem Gesamtkonzept folgend wird angenommen, dass diese Aufgabe für eine nähere Analyse hinsichtlich relevanter Details im Teilschritt ‚Aufgaben- und Datenselektion‘ (Abschnitt 3.3.2) ausgewählt wird. Als Datenquelle dient eine Kamera, welche die Arbeitsfläche aus einer Ansicht von oben

(engl. *top down*) überwacht. Sie wird für die Analyse genutzt, indem Bilder der Arbeitsfläche **nach** Platzierung der Bräunlinge aufgenommen werden. Weiter wird angenommen, dass der Prozess mehrmals mit gleichbleibenden Konfigurationen (Objekte, Einstellungen der Öfen, usw.) ausgeführt wird und jedes Bild ein Label am Ende der Ausführung des Gesamtprozesses erhält, d.h. nach dem Sinterungsschritt. Als Kriterium für die Bewertung wird die Qualität des finalen Produkts gewählt. Des Weiteren beschränken sich die Experimente auf einen **Zweiklassenfall**, was bedeutet, dass das Prozessergebnis entweder erfolgreich oder fehlerbehaftet ist. Außerdem wird angenommen, dass es eindeutige Objektmerkmale in einem aufgenommenen Bild gibt, deren Auftreten für die Zuordnung zur positiven oder negativen Klasse verantwortlich sind (relevante Prozessdetails).

Um die Effektivität eines Analyseansatzes zu evaluieren, ist eine klare Referenz erforderlich, die mit den Ergebnissen der Analyse abgeglichen werden kann. Aus diesem Grund werden für jedes Szenario im Vorfeld die relevanten Prozessdetails festgelegt und anschließend überprüft, ob diese mit den von den entwickelten Methoden extrahierten Details übereinstimmen. Dieser Vorgehensweise liegt die Absicht zugrunde, die Genauigkeit und Zuverlässigkeit der Analysemethoden anhand eines klar definierten Bezugsrahmens zu bewerten. Bestätigt sich die Eignung der Verfahren für diese Problemstellung, können sie zum Finden noch unbekannter relevanter Prozessdetails in anderen Szenarien eingesetzt werden. Für eine eingehendere Untersuchung der Methoden beschreiben die entworfenen Szenarien außerdem unterschiedlich komplexe Varianten des gleichen Prozesses und somit verschiedene Situationen, die im Zusammenhang mit der Ausführung des Platzierungsschritts auftreten können.

4.3.2.1 SZENARIO 1: FARBE

Szenario 1 beschreibt eine einfache Variante des Platzierungsschritts, in der ein einziges Werkstück auf eine Platte platziert werden soll. Dabei wird angenommen, dass den Prozessausführenden in der Arbeitsumgebung verschiedene Teile zur Verfügung stehen. Das Prozessmodell enthält lediglich die Aufgabenbeschreibung, **dass** ein Werkstück zu platzieren ist, gibt aber keine näheren Anweisungen, **welches** der Werkstücke dafür verwendet werden soll. Folglich wählen die Prozessausführenden selbst eines der Objekte zur Ausführung der Aufgabe aus. Die verfügbaren Werkstücke weisen alle identische Form, Größe und Materialeigenschaften auf, variieren jedoch in ihrer Farbe. Zur Vereinfachung wird davon ausgegangen, dass lediglich zwei Farben auftreten und die Werkstücke entweder grün oder blau sind. Für dieses Szenario wird festgelegt, dass die Platzierung eines grünen Objekts auf der Platte zu einem fehlerbehafteten und die Platzierung eines blauen Objekts zu einem erfolgreichen Prozessergebnis führen. Das relevante Prozessdetail

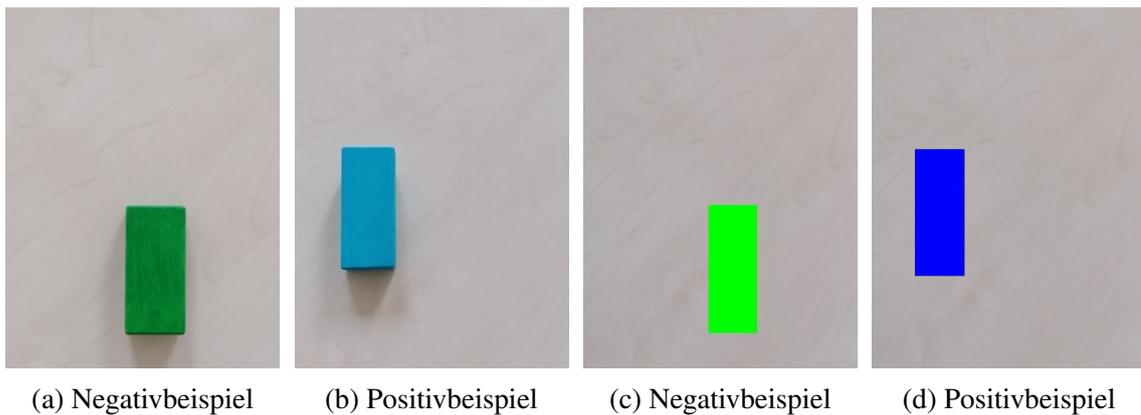


Abbildung 17: Negativ und positiv gelabelte Beispiele zu Szenario 1, aufgenommen mit einer Kamera (links) und synthetisch erzeugt (rechts).

bezieht sich somit auf das **Farbmerkmal** eines Werkstücks und formuliert seine Ausprägung in ‚Blau‘ als notwendige Bedingung, die während der Prozessausführung beachtet werden muss. Im Kontext des Metallspritzgussprozesses kann die Farbe von Werkstücken nach der Entbinderung Hinweise auf ihren Feuchtigkeitsgehalt geben, und somit Rückschlüsse darauf zulassen, wie viel Bindemittelflüssigkeit noch im Fertigungsteil verblieben ist. In anderen Abläufen ist aber auch vorstellbar, dass die Objekte mit verschiedenen Bindemitteln hergestellt werden, die zu Unterschieden in der Farbe führen. In beiden Fällen muss der Entbinderschnitt unter Umständen angepasst werden. Ist dieser allerdings fixiert, ist der Feuchtigkeitsgehalt oder der Bindemitteltyp und damit die Farbe der Werkstücke für das Prozessergebnis entscheidend.

Abbildungen 17a und 17b zeigen Beispiele gelabelter Aufnahmen des Arbeitsbereichs nach Abschluss der Platzierungsaufgabe im Rahmen von Szenario 1. Zur modellhaften Darstellung des Szenarios und zur Entwicklung eines ersten Prototyps werden einfache, konvexe Objekte verwendet und ein simpler Hintergrund gewählt. Diese Entscheidung ermöglichte eine genauere Kontrolle über den Versuchsaufbau und unterstützte die Erkennung von potenziellen Schwierigkeiten bei der Implementierung. Durch diesen Ansatz können zunächst die Grundfunktionalitäten von Verfahren evaluiert werden, bevor komplexere Objekte in Betracht gezogen werden. Zur effizienteren Simulation mehrerer Prozessausführungen, wird auf die synthetische Erzeugung von Bilddaten zurückgegriffen. Um verschiedene Szenen des Aufbaus zu simulieren, wird das zu platzierende Objekt durch eine rechteckige Form angenähert und auf dem als einzelnes Bild abgespeicherten Hintergrund an zufälligen Positionen gemalt. Dabei werden für ‚Grün‘ und ‚Blau‘ gezielt die reinen Primärfarben des RGB-Farbraums verwendet, um sie möglichst gut voneinander unterscheiden zu können. Abbildungen 17c und 17d zeigen Beispiele synthetisch erzeugter Bilder zu Szenario 1. Unter anderem ermöglichen synthetische Daten die Ge-

nerierung eines beliebig großen Datenbestands und die Variation verschiedener Faktoren wie beispielsweise Verteilung oder Qualität. Dies ist von entscheidender Bedeutung für die Verwendung von Ansätzen aus dem maschinellen Lernen, da derartige Verfahren eine ausreichend große Menge qualitativ hochwertiger Daten erfordern [130].

4.3.2.2 SZENARIO 2: FORM UND POSITION

Im Gegensatz zu Szenario 1, in welchem nur ein Objektmerkmal relevant ist (Farbe des platzierten Objekts muss blau sein), ist Szenario 2 komplexer gestaltet. Ziel ist damit die Untersuchung der Methoden bei steigender Komplexität der Szenen um sich realen Prozessumgebungen anzunähern und damit verbundene Probleme zu identifizieren. Auch Szenario 2 behandelt den Platzierungsschritt von Bräunlingen auf eine Platte, die nachfolgend in einen Sinterofen eingesetzt wird (Abschnitt 4.3.1). Im Unterschied zu Szenario 1 betrifft die Aufgabenbeschreibung im Prozessmodell diesmal die Platzierung von **vier** Objekten. Dabei stehen in der Prozessumgebung genau vier Werkstücke zur Verfügung, die sich lediglich in ihrer Form unterscheiden: zwei runde und zwei eckige Werkstücke. Es wird erneut angenommen, dass die Aufgabenbeschreibung im Prozessmodell abstrakt gehalten ist. Somit enthält es lediglich die Information, **dass** vier Objekte platziert werden sollen und gibt keine näheren Anweisungen dazu **welches** der Werkstücke **wohin** auf der Platte platziert werden soll. Als Bedingung für Prozesserfolg wird in diesem Szenario festgelegt, dass mindestens ein rundes Objekt im oberen Siebtel der Platte platziert werden muss. Abbildung 18 zeigt mögliche Szenen nach Platzierung der Objekte. Das Szenario ist motiviert durch das charakteristische Problem der ungleichmäßigen Wärmeverteilung in einem Sinterofen. Bestimmte Komponenten mit spezifischen Eigenschaften müssen in den heißeren Bereichen des Ofens platziert werden, um eine vollständige Verdichtung der

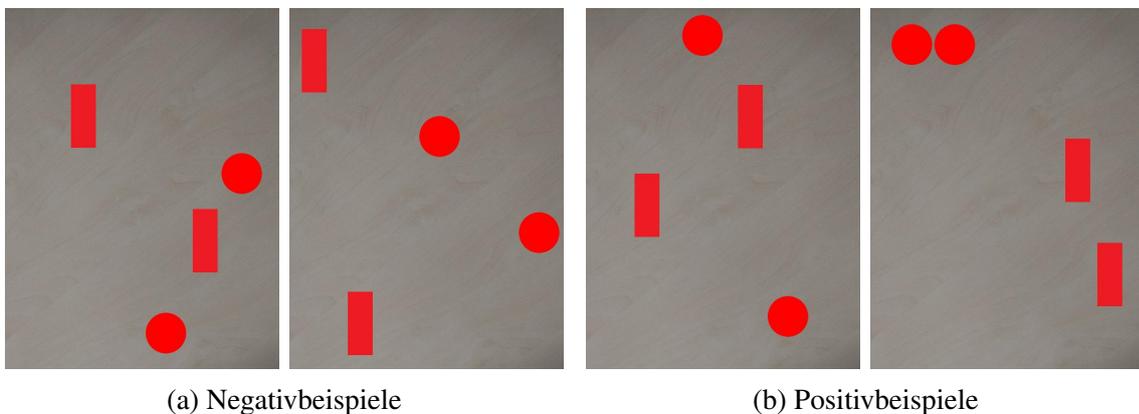


Abbildung 18: Synthetisch generierte Bilddaten zu Szenario 2.

Metallpartikel zu gewährleisten. Entgegen der festgelegten Bedingung platzieren Prozess-TeilnehmerInnen aufgrund unzureichender Information im Prozessmodell die vier Objekte an willkürlichen Positionen auf der Platte. Auch für dieses Szenario werden die Bilddaten synthetisch erzeugt und hinsichtlich der Erfüllung der vorgegebenen Bedingung gelabelt. Die definierte Bedingung umfasst zwei Merkmale: zum einen das **Formmerkmal** mit der Ausprägung ‚Rund‘ und zum anderen das **Positionsmerkmal** mit der Ausprägung ‚Oberes Siebtel der Platte‘. Im Vergleich zu Szenario 1 steigt die Komplexität hinsichtlich der Anzahl der Objekte in der Szene und der relevanten Prozessdetails.

Die Bilddaten werden gemäß den definierten relevanten Prozessdetails pro Szenario generiert, wobei je nach Analyseansatz verschiedene Mengen an Daten erzeugt werden. Die Daten dienen als Eingabe für den Analyseschritt des Gesamtkonzepts. Die konkrete Verarbeitung der Daten und die Extraktion des relevanten Prozessdetails aus den Daten wird in den beiden nachfolgenden Kapiteln mit verschiedenen Ansätzen näher erläutert.

4.4 ANALYSE UNSTRUKTURIERTER BILDDATEN MIT XAI

Zunächst wird durch den Einsatz einer Methode aus dem Bereich der erklärbaren künstlichen Intelligenz die direkte Extraktion relevanter Prozessdetails aus unstrukturierten Bilddaten demonstriert und anhand der beiden Szenarien evaluiert. Unstrukturierte Daten zeichnen sich durch einen hohen Informationsgehalt und einen umfangreichen Merkmalsraum aus. Um die Problemstellung der Arbeit zu adressieren, sind Methoden erforderlich, die in der Lage sind, relevante Merkmale aus diesem Raum zu extrahieren. Neben klassischen Verfahren aus dem Computersehen (engl. *computer vision*) [263], haben sich Methoden aus der künstlichen Intelligenz als besonders effizient und effektiv in der Erkennung und Extraktion von Merkmalen aus Bilddaten erwiesen. Erklärbare künstliche Intelligenz baut auf dieser Stärke auf und deckt darüber hinaus auf, wie derartige Systeme zu ihren Ergebnissen kommen. Diese Erklärungen ermöglichen die Differenzierung zwischen relevanten und irrelevanten Merkmalen.

4.4.1 EINFÜHRUNG IN KÜNSTLICHE INTELLIGENZ UND XAI

Der Begriff der **künstlichen Intelligenz** (engl. *artificial intelligence*) umfasst alle Ansätze, die sich mit der Automatisierung von Aufgaben durch Übertragung menschlicher Fähigkeiten auf Maschinen beschäftigen [140]. Dies sind beispielsweise Fähigkeiten wie logisches Denken, Kreativität oder Lernen. Bezüglich Letzterem hat sich das Teilgebiet des

maschinellen Lernens (engl. *machine learning*) entwickelt. Der Schwerpunkt liegt darauf Computer zu trainieren, aus Erfahrungen (Daten) zu lernen und sich damit selbstständig zu verbessern [24]. Der englische Begriff **Deep learning** ist eine spezielle Form des maschinellen Lernens, das zu einem enormen Fortschritt in diesem Bereich geführt hat. Ziel ist die Erkennung komplexer Strukturen und Muster in großen Datenmengen. Dafür werden mehrschichtige **neuronale Netze** (engl. *neural networks*) genutzt, die in der Lage sind, abstrakte Darstellungen von Daten zu erlernen. Durch ihre Nutzung können komplexe Probleme gelöst werden, weshalb sich diese Technik in viele Forschungsbereiche ausgebreitet hat, z.B. in der Bild- und Sprachverarbeitung, im autonomen Fahren, oder in der Medizin [246]. Neuronale Netze werden oft als Blackbox betrachtet, d.h. dass sowohl die Funktionsweise des Algorithmus als auch die finalen Werte der Parameter bekannt sind, allerdings nicht wieso ein Ergebnis erreicht wird. Methoden aus dem Bereich der **erklärbaren künstlichen Intelligenz** (engl. *Explainable Artificial Intelligence (XAI)*) sind in der Lage, Ergebnisse zu erklären und somit Entscheidungsprozesse von neuronalen Netzen transparent zu machen. Sie stehen eng in Verbindung mit dem englischen Terminus *Trust*, welcher das Vertrauen in die Entscheidungen eines Systems beschreibt. Dieser Aspekt gewinnt besondere Relevanz, wenn das Modell für die Entscheidungsfindung in sensiblen Anwendungsbereichen genutzt wird, wie z.B. in der medizinischen Diagnostik, der Risikobewertung von PatientInnen oder der Erkennung terroristischer Absichten [117, 223]. In dieser Arbeit wird die Fähigkeit zur Erklärung von Entscheidungen genutzt, um relevante Prozessdetails zu bestimmen. Somit werden falsche Entscheidungen in Prozessausführungen verhindert, um zukünftig Fehler zu vermeiden [70]. In Abschnitt 4.4.1.2 wird die Vorgehensweise von XAI-Ansätzen noch einmal genauer erläutert. Abbildung 19 zeigt zusammenfassend, wie die verschiedenen Teilbereiche der künstlichen Intelligenz hierarchisch in Beziehung stehen. Im Sinne der Konsistenz werden die englischen Fachtermini verwendet.

4.4.1.1 NEURONALE NETZE

Neuronale Netze beschreiben im Wesentlichen die Struktur eines gerichteten Graphen und umfassen verschiedenen Schichten, jeweils bestehend aus einer Menge an Knoten (sog. Neuronen), die über Kanten mit- und untereinander verbunden sind [107]. Die Kanten tragen Gewichte, die entsprechend ihrem Wert eine Verbindung verstärken (positiver Wert) oder hemmen (negativer Wert). Einzelne Knoten berechnen ihre Ausgabe durch eine Menge an Eingaben (Ergebnisse aus vorherigen Schichten), die durch Kanten gewichtet sind, und eine Aktivierungsfunktion. Informationen werden so von der Eingabeschicht bis zur

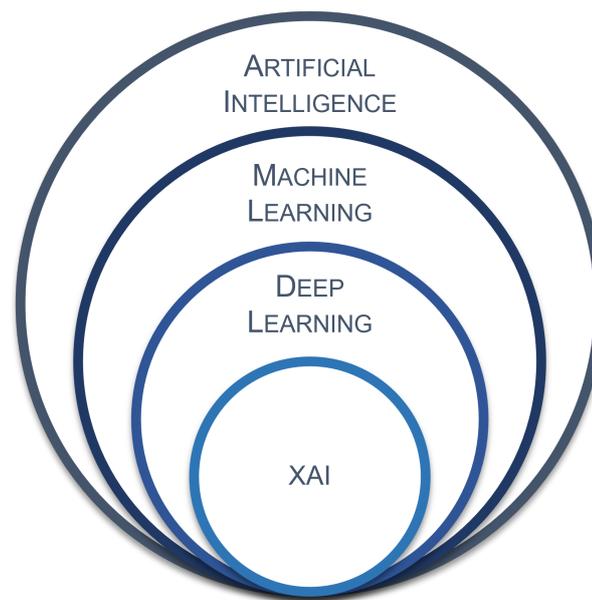


Abbildung 19: Einordnung verschiedener Fachtermini aus dem Bereich der künstlichen Intelligenz nach [246].

Ausgabeschicht des Netzes weitergegeben und innerhalb der einzelnen Schichten verarbeitet. Die Menge und Art der Schichten zwischen diesen beiden äußeren Schichten wird durch die Architektur des Netzes bestimmt, wobei sich je nach Anwendungsgebiet verschiedene Architekturen eignen. Bekannte Beispielnetze mit verschiedenen Architekturen und Schichten sind **Faltungsnetzwerke** (engl. *Convolutional Neural Networks (CNNs)*), rekurrente neuronale Netze (engl. *recurrent neural networks*), Autoencoder, oder LSTM-Netze (engl. *Long/Short-Term Memory*). Dabei sind CNNs für diese Arbeit von besonderem Interesse. CNNs haben eine oder mehrere Faltungsschichten (engl. *convolutional layers*), die vollständig verbunden oder, an den englischen Fachterminus angelehnt, *ge-poolt* sein können. Diese sog. *Pooling*-Schichten reduzieren die betrachtete Datenmenge und werfen überflüssige Informationen. Jede Faltungsschicht führt eine Faltung auf einer Eingabe durch, bevor sie diese Information an die nächste Schicht weiterleitet. Aufgrund dieses Faltungsprozesses kann das Netzwerk erheblich tiefer und komplexer sein als andere Netze und dabei deutlich weniger Parameter benötigen. CNNs sind besonders gut für die Erkennung von Inhalten in Bildern und Videos geeignet und für die natürliche Sprachverarbeitung. Sie kommen daher in der Bildkategorisierung und Signalverarbeitung verstärkt zum Einsatz [267].

Abhängig von der Anzahl der Neuronen in der Ausgabeschicht, gibt ein neuronales Netz ein oder mehrere numerische Werte aus, die für verschiedene Anwendungen genutzt werden können. Eine typische Anwendung ist die **Klassifizierung**, bei der das neuronale Netz genutzt wird, um für eine bestimmte Eingabe (z.B. ein Bild) eine Zuordnung zu

einer Klasse zu berechnen (z.B. ‚Hund‘ oder ‚Katze‘). Die Ausgabeschicht kann dann beispielsweise so viele Neuronen enthalten, wie Klassen zur Verfügung stehen. In diesem Kontext repräsentiert die Ausgabe des Netzwerks einen Skalar für jede Klasse, der als Vorhersage (engl. *prediction*) für die Zuordnung zu dieser spezifischen Klasse interpretiert wird. Hierbei bedeutet ein Wert von ‚1‘, dass die Zuordnung zur betreffenden Klasse höchstwahrscheinlich ist, während ein Wert von ‚0‘ eine äußerst unwahrscheinliche Zuordnung darstellt [146]. Um überhaupt eine Vorhersage für einen Eingabewert zu erzeugen, muss das neuronale Netz auf einem gegebenen Datensatz trainiert werden. Während des Trainings lernt das Modell, Muster zu erkennen und komplexe Zusammenhänge zu verstehen. Es lernt dadurch beispielsweise, welche Merkmale in einem Merkmalsraum für eine Klasse von Bedeutung sind und wo die Entscheidungsgrenze liegt. Der Trainingsprozess wird iterativ durchgeführt, wobei die Gewichte der Kanten kontinuierlich angepasst werden. Die Qualität des trainierten Netzes wird anhand bestimmter Kennzahlen gemessen. Darunter bestimmt die Genauigkeit (engl. *accuracy*) den Prozentsatz korrekter Vorhersagen im Verhältnis zur Gesamtanzahl der Vorhersagen durch Verwendung gelabelter Daten. Der Verlust (engl. *loss*) quantifiziert dagegen die Abweichungen zwischen den vom Modell vorhergesagten Werten und den tatsächlichen Labels¹. Die Verwendung von gelabelten Daten für diesen Zweck wird als überwachtes Lernen (engl. *supervised learning*) bezeichnet und wird meistens zum Training von neuronalen Netzen genutzt. Die Gewichtsadjustierungen erfolgen mit dem Ziel, die Accuracy des Modells zu erhöhen und den Loss zu minimieren.

Das Training von neuronalen Netzen wird auf einem sog. Trainingsdatensatz durchgeführt. Dagegen werden zur Bestimmung der Accuracy des Netzes Validierungsdaten herangezogen. Mithilfe dieser wird die Fähigkeit des Modells zur Verarbeitung bisher un-gesehener Daten beurteilt. Damit kann das Auftreten von *Overfitting* identifiziert werden. Dieser Begriff beschreibt die Überanpassung des Modells an die Trainingsdaten, was zu ungenauen Vorhersagen auf neuen Daten führt. Das Nachlassen oder sogar Verschlechtern der Modellleistung auf den Validierungsdaten während die Leistung auf den Trainingsdaten verbessert wird, deutet darauf hin, dass das Modell zu stark auf die spezifischen Trainingsdaten zugeschnitten ist. Daneben gibt es noch eine Reihe weiterer Parameter und Aspekte, die für ein effektives Training sorgfältig ausgewählt und angepasst werden sollten [133].

¹Aus Gründen der Eindeutigkeit werden im Folgenden die englischen Fachbegriffe ‚Accuracy‘ und ‚Loss‘ verwendet.

4.4.1.2 ANSÄTZE IM BEREICH XAI UND METHODENAUSWAHL

Sind Architektur eines neuronalen Netzes und Aktivierungsfunktionen bekannt, kann die Berechnung einer Vorhersage theoretisch mathematisch nachvollzogen werden. Dennoch gestaltet sich die tatsächliche Interpretation des Vorgangs aus so einer Darstellung heraus äußerst komplex. Zum einen ist der zugrundeliegende Sachverhalt durch eine rein mathematische Repräsentation schwer verständlich. Zum anderen wird die Interpretation durch die Beteiligung von Millionen von Parametern, die zur Generierung der Vorhersage verwendet werden, zusätzlich erschwert. Die Zusammenhänge zwischen Parametern und den Auswirkungen auf das Gesamtsystem sind in ihrer Gesamtheit kaum mehr in einem übergreifenden Kontext nachvollziehbar. Techniken aus dem Bereich XAI lösen dieses Problem **Ante-hoc** oder **Post-hoc** auf verschiedene Weise [117, 287]:

- Ante-hoc-XAI beschreibt inhärent interpretierbare Modelle, die von Natur aus transparent sind. Diese Methoden sind **modellspezifisch** und umfassen beispielsweise generalisierte additive Modelle [52], hybride Systeme [153] oder auch Ansätze mit Entscheidungsbäumen und regelbasiertem Lernen [26].
- Post-hoc-Methoden sind **modellagnostisch** und bieten Erklärungen auf Merkmalsebene, indem sie mit einem interpretierbaren Modell versuchen, das Verhalten eines Originalmodells zu approximieren. Sie können in globale und lokale Erklärungsansätze unterteilt werden. Lokale Methoden konzentrieren sich auf die einzelnen Eingabedaten und liefern individuelle Erklärungen zu diesen Daten. Bekannte Ansätze sind LIME [223], SHAP [157], LORE [102]. Dagegen legen globale Erklärungen den Fokus auf das Modell und vermitteln ein Verständnis für dessen Entscheidungsprozess, wie beispielsweise die Ansätze BETA [150] und GAM [122]. Dabei können Sammlungen lokaler Erklärungen ebenfalls für eine globale Erklärung genutzt werden [26]. Neben dem ‚Lokal-Global‘-Kriterium können bisherigen Verfahren zusätzlich auf Grundlage der verwendbaren Datentypen (z.B. Tabellen, Bilder, Texte, Zeitfolgen) oder der angewandten Methoden unterteilt werden [48, 167].

Insbesondere modellagnostische Ansätze (post-hoc) sind in dieser Arbeit von Relevanz, da die gesammelten Daten während einer Prozessausführung eine Vielzahl unbekannter Informationen enthalten. Dadurch gestaltet es sich schwierig, ein passendes Modell gezielt auszuwählen, weshalb flexible Verfahren eingesetzt werden müssen, die unabhängig vom Modellen funktionieren. Besonders interessant sind darunter Methoden, die in der Lage sind, Erklärungen in Form von Regeln zu extrahieren (engl. *rule extraction*), die

Wichtigkeit einzelner Merkmale zu berechnen (engl. *feature importance*) oder interessante Regionen bzgl. einer Entscheidung in Bilddaten (engl. *saliency maps*) hervorzuheben. Wie in Abschnitt 3.3.4 erläutert, besteht das Ziel des Analyseschritts in

- (i) dem Finden relevanter Merkmale,
- (ii) der Extraktion einer Regel aus diesen Merkmalen, welche eine allgemeine Bedingung für Prozesserverfolg enthält und
- (iii) der Umsetzung mit einer Methode, die mit Bilddaten kompatibel ist.

Zur Erfüllung aller Anforderungen wird für die Umsetzung des Analyseschritts mit unstrukturierten Eingabedaten der Ansatz **Local Interpretable Model-Agnostic Explanations** (LIME) ausgewählt. Diese Entscheidung liegt in folgenden Punkten begründet.

Wichtigkeit einzelner Merkmale: Die Methode von LIME ist der Bestimmung der Wichtigkeit von Merkmalen zuzuordnen [48, 167]. Diese Bewertung ist entscheidend für die Identifikation relevanter Merkmale, die in Verbindung mit dem Prozesserverfolg stehen. Außerdem ermöglicht sie die Unterscheidung zwischen relevanten und irrelevanten Merkmalen. Die Betrachtung von ausschließlich relevanten Merkmalen ist eine Voraussetzung für die Erzeugung von präzisen und zuverlässigen Regeln.

Eignung für Bilddaten: Existierende Ansätze zur Regelextraktion, welche ebenfalls die Problemstellung der Arbeit adressieren, erfordern in gewisser Weise strukturierte Daten. Sie werden in Abschnitt 4.5 näher beleuchtet. Dagegen eignet sich LIME für lokale Erklärungen verschiedener Datentypen, einschließlich Bilddaten. Die Fähigkeit, interessante Regionen in Bildern hervorzuheben, qualifiziert LIME für die Analyse dieses Datentyps.

Popularität und Code-Verfügbarkeit: LIME ist eines der ersten Verfahren um Entscheidungen von komplexen Modellen zu erklären und gilt als eine der bekanntesten Techniken in diesem Kontext [48, 117, 209]. Zahlreiche Ansätze haben sich auf Basis der Grundprinzipien von LIME entwickelt und verschiedene Aspekte erweitert. Diese Entwicklungen sind maßgeblich durch die geringen Anforderungen und die außerordentliche Flexibilität von LIME ermöglicht worden. Die Beliebtheit der Methode hat zu einer Fülle von Tutorials und einer umfangreichen Code-Basis geführt, die wiederum zu einer hohen Verfügbarkeit und einem schnellen Zugang zu dieser Technik beigetragen haben. Die vorhandene Implementierungsinfrastruktur ermöglicht es Forschenden, LIME leicht in neue Kontexte zu integrieren und aufbauende Konzepte darauf zu entwickeln und zu evaluieren.

Um eine allgemeine Regel r zu bestimmen, welche die Bedingung für Prozesserverfolg im Kontext einer Aufgabe enthält, reicht die individuelle Betrachtung lokaler Erklärungen

nicht aus. Eine **lokale Erklärung** ist das Analyseergebnis einer einzelnen Prozessausführung bzw. eines Bilds. Dabei sind dieser womöglich nicht die Gesamtheit relevanter Prozessdetails zu entnehmen, sondern lediglich Teilaspekte. Um dieses Problem zu adressieren, kann aus einer Menge lokaler Erklärungen eine **globale Erklärung** abgeleitet werden [26]. Diese Tatsache wird genutzt um auf Basis der von LIME erzeugten lokalen Erklärungen r zu bestimmen, die der definierten Ausgabe des Analyseschritts entspricht. Durch die Integration dieses sog. **Globalisierungsschritts**, wie in Abschnitt 4.4.3 näher erläutert, wird die Methodik von LIME zur Bestimmung der Merkmalswichtigkeit um die Fähigkeit zur Regelgenerierung erweitert. Diese Anpassung macht die Methode für den Anwendungsfall dieser Arbeit nutzbar und eröffnet neue Möglichkeiten zur Interpretation komplexer Modelle und zur Extraktion von relevanten Informationen aus den Daten. Der Globalisierungsschritt erweitert somit den methodologischen Rahmen von LIME und ermöglicht die Integration dieser Methode in den spezifischen Kontext von Prozessen.

4.4.2 LOCAL-INTERPRETABLE MODEL-AGNOSTIC EXPLANATIONS

Das Konzept von LIME [223] ermöglicht die Erklärung von Vorhersagen beliebiger Klassifikationsmodelle in einer verständlichen Art und Weise. Eine von LIME erzeugte lokale Erklärung zu einer Vorhersage ist ein Bild, in dem bestimmte Regionen hervorgehoben sind. Diese Regionen sind die Gründe für die Zuordnung des Bilds zu einer bestimmten Klasse durch einen Klassifikator, z.B. einem neuronalen Netz. Durch diesen Ansatz wird mit Hilfe eines interpretierbaren Modells (Bild mit hervorgehobenen Regionen) die Vorhersage eines Klassifikators für eine Eingabe erklärt. Abbildung 20 zeigt lokale Erklärungen zu Vorhersagen für die Bildklassifizierung durch das neuronale Netz ‚Google Inception‘ [262]. Die drei vorhergesagten Klassen mit den höchsten Wahrscheinlichkeiten p sind ‚E-Gitarre‘ ($p = 0.32$), ‚Akustikgitarre‘ ($p = 0.24$) und ‚Labrador‘ ($p = 0.21$).

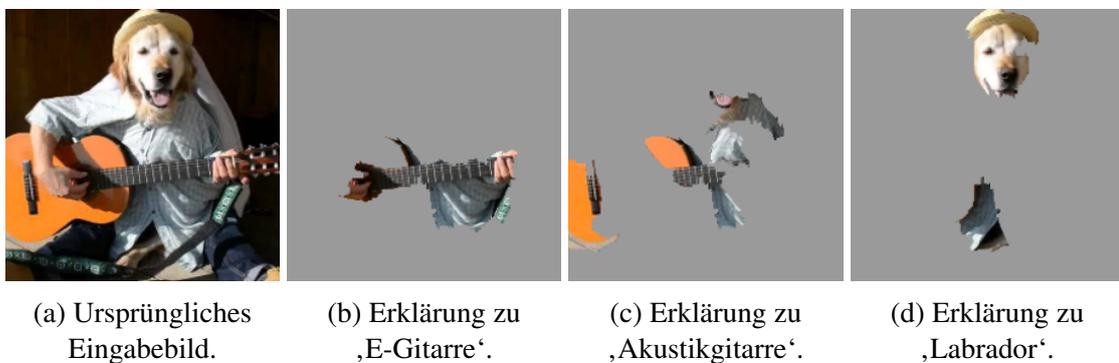


Abbildung 20: Von LIME erzeugte lokale Erklärungen einer Vorhersage zu verschiedenen Klassen für ein Eingabebild [223].

Um lokale Erklärungen in Form von derartigen Bilder zu erzeugen, erfolgt zunächst ein Segmentierungsschritt, der ein Eingabebild in eine Menge an Superpixeln unterteilt. Dafür wird der Formalisierung von [223] gefolgt und angenommen, dass das Eingabebild als Tensor mit drei Farbkanälen $x \in \mathbb{R}^d$ repräsentiert ist. Ein **Superpixel** kann als Flicker (engl. *patch*) betrachtet werden, der eine zusammenhängende, homogene Region von Pixeln beschreibt (z.B. Pixel mit selber oder ähnlicher Farbe). Das segmentierte Bild lässt sich dann als binärer Vektor $x' = (1, \dots, 1) \in \{0, 1\}^{d'}$ formalisieren, wobei d' die Anzahl an Superpixeln umfasst. LIME erzeugt anschließend eine Menge von Bildern zu x' , in denen einzelne Superpixel ausgeblendet werden. Solch ein Bild wird ebenfalls durch einen binären Vektor $z' \in \{0, 1\}^{d'}$ beschrieben, wobei ‚0‘ die Abwesenheit und ‚1‘ die Präsenz eines bestimmten Superpixels kennzeichnet. Dann kann z' wiederum in einem Tensor mit drei Farbkanälen $z \in \mathbb{R}^d$ dargestellt werden, indem alle abwesenden Superpixel ausgegraut oder geschwärzt werden. Der Klassifikator $f: \mathbb{R}^d \rightarrow \mathbb{R}$ erhält dann z als Eingabe und berechnet die Wahrscheinlichkeit $f(z)$, dass z zu einer bestimmten Klasse gehört. Die Menge \mathcal{Z} umfasst verschiedene Permutationen solcher Bilder mit zugehörigen Labels. Je mehr Superpixel in solch einem Bild anwesend oder sichtbar sind, desto näher ist das Bild am ursprünglichen Binärvektor x' (und damit auch an x). Diese Lokalität wird gemessen durch π_x . In LIME wird dieser Faktor als Gewichtung für das Gesamtergebnis mit einbezogen, was die Methode robuster gegenüber Stichprobenrauschen macht. Die gelabelten Permutationen aus \mathcal{Z} werden genutzt, um das lokale Verhalten von f mit Hilfe eines interpretierbaren Modells g (z.B. einem linearen Modell) an der Stelle x zu lernen:

$$\mathcal{L}(f, g, \pi_x) = \sum_{z, z' \in \mathcal{Z}} \pi_x(z) (f(z) - g(z'))^2 \quad (4.1)$$

Dabei ist $\mathcal{L}(f, g, \pi_x)$ eine Verlustfunktion, die misst, wie vertrauenswürdig g bei der Annäherung an f in der durch π_x definierten Lokalität ist. Zur Veranschaulichung illustriert Abbildung 21 noch einmal das Vorgehen von LIME. Die Grafik verdeutlicht, wie komplex eine unbekannte Trennfunktion f zweier Klassen (rosa und hellblau) in einem Blackbox-Modell aussehen kann. LIME approximiert diese Funktion an einer Stelle durch ein lineares Modell g (gestrichelte Linie). Auch wenn das ursprüngliche Modell zu komplex ist, um es global zu erklären, ermöglicht LIME eine Erklärung, die lokal vertrauenswürdig ist. Insgesamt lässt sich eine von LIME erzeugte Erklärung ξ wie folgt formalisieren:

$$\xi(x) = \operatorname{argmin}_{g \in G} \mathcal{L}(f, g, \pi_x) + \Omega(g) \quad (4.2)$$

Der Typ des Erklärmodells G und die Verlustfunktion \mathcal{L} kann beliebig gewählt werden. Dabei beschreibt $\Omega(g)$ die Komplexität des Erklärmodells und muss abhängig davon an-

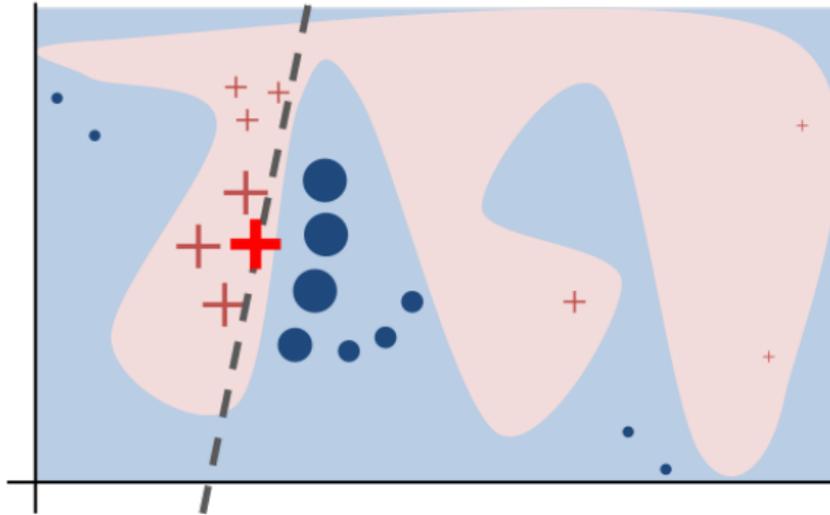


Abbildung 21: LIME findet eine lokale Trennfunktion (gestrichelte Linie) zweier Klassen (rosa und hellblau) an einem Datenpunkt (dickes rotes Kreuz) durch Verwendung weiterer Datenpunkte in der Nähe (dünne rote Kreuze) [223].

gepasst werden. Ziel von LIME ist die Minimierung von $\mathcal{L}(f, g, \pi_x)$ und die Wahl eines noch gut interpretierbaren Erklärmodells, sodass $\Omega(g)$ klein genug bleibt.

In den von LIME generierten Bildern wird der Zusammenhang zwischen dem Vorhandensein bestimmter Superpixel und einem Label deutlich sichtbar gemacht. Dies ermöglicht die Identifizierung relevanter Merkmale in einem Bild, ohne dass zusätzliches Kontextwissen über das Bild erforderlich ist. Diese Eigenschaft erweist sich als äußerst vorteilhaft, insbesondere für Problemstellungen wie in dieser Arbeit, in denen der Merkmalsraum und die Relevanz einzelner Merkmale unbekannt ist. Im nachfolgenden Abschnitt wird die Umsetzung des Analyseschritts zur Extraktion relevanter Prozessdetails durch die Verwendung von LIME detailliert erläutert.

4.4.3 UMSETZUNG MIT LIME

Zur Umsetzung des Analyseschritts mit LIME sind drei Teilschritte notwendig, die in Abbildung 22 zusammengefasst sind. Analog zum Formalismus in Abschnitt 3.3 bilden die Eingabe in den Schritt gelabelte Bilddaten $V = \{(d(a)_i, l_i) | i \in I\}$. Dabei entspricht I der Menge der Prozessausführungen und d einer Kamera zur Aufnahme von Bildern nach der Ausführung von Aufgabe a . Die Ausgabe des Schritts sind relevante Prozessdetails, beschrieben durch r_{ud} .



Abbildung 22: Teilschritte zur Umsetzung des Analyseschritts für unstrukturierte Bilddaten mit LIME.

4.4.3.1 TRAINING DES CNN UND ANWENDUNG VON LIME

Training des CNN. Zunächst werden die Bilddaten V genutzt, um ein CNN zu trainieren. Dadurch lernt das CNN eine (noch unbekannte) Entscheidungsgrenze in einem ebenfalls gelernten Merkmalsraum. Dabei werden verschieden komplexe Merkmale pro Schicht betrachtet [115]. Die erste Faltungsschicht extrahiert einfache Merkmale (engl. *low-level features*) wie Kanten, Linien und Ecken. Dagegen extrahieren höhere Schichten komplexere Merkmale mit semantischer Bedeutung. So trennt die gelernte Entscheidungsgrenze $V_{l=1} := \{(d(a), l) \in V \mid l = 1\}$ von Daten zu fehlerbehafteten Prozessergebnissen $V_{l=0} := \{(d(a), l) \in V \mid l = 0\}$ (Abschnitt 3.3.4). Abhängig von der Komplexität der Problemstellung bzw. der Bilddaten muss eine passende Netzarchitektur mit entsprechend vielen Faltungsschichten gewählt werden.

Lokale Erklärungen mit LIME. Anschließend wird das trainierte CNN mit Hilfe von LIME erklärt (Abschnitt 4.4.2). Dabei liegt der Fokus auf dem Finden einer Erklärung, oder einem Kriterium, für erfolgreiche Prozessausführungen. Deshalb wird LIME genutzt, um lokale Erklärungen der **positiv** gelabelten Bilddaten $V_{l=1}$ zu erzeugen. Diese dienen somit als Eingabe für den Teilschritt. Die negativ gelabelten Daten werden an dieser Stelle nicht mehr verwendet, könnten aber in einer Variante des Ansatzes genutzt werden, um Prozessfehlschlag anstatt Prozesserfolg zu erklären (Anpassung der rechten Seite von r erforderlich). Das Ergebnis ist eine lokale Erklärung $g(v)$ in Form eines Flickerbilds zu jedem positiv gelabelten Bild $v \in V_{l=1}$, bei dem die relevanten Superpixel sichtbar und irrelevante Teile des Bilds ausgeblendet sind. Die sichtbaren Superpixel entsprechen Bildregionen, die relevante Details bzgl. Aufgabe a enthalten und zur Maximierung des Gesamtprozessenerfolgs berücksichtigt werden müssen.

4.4.3.2 GLOBALISIERUNG

LIME erzeugt lediglich lokale Erklärungen, die jeweils relevante Regionen eines einzelnen Bilds bestimmen. Diese sind für die Ableitung einer allgemeinen Regel ungenügend, da diese alle relevanten Details für die analysierte Aufgabe umfassen soll. Zwar

kann die Betrachtung einer einzelnen lokalen Erklärung in einfachen Prozessschritten mit wenig Merkmalen und Merkmalsausprägungen zielführend sein (Szenario 1, Abschnitt 4.3.2.1), ist aber in komplexeren Situationen nicht mehr ausreichend (Szenario 2, Abschnitt 4.3.2.2). Eine lokale Erklärung deckt grundsätzlich nur eine Ausprägung eines relevanten Merkmals ab und adressiert somit nur einen Teilaspekt einer generellen Regel. Darüber hinaus ist eine allgemeine Schlussfolgerung, die allein auf einer einzelnen lokalen Erklärung beruht, wenig belastbar und anfällig für Ausreißer. Diese Vorgehensweise würde die Integration geeigneter Verfahren zur Auswahl einer aussagekräftigen Stichprobe erfordern. Um eine robuste generelle Regel zu extrahieren, welche die analysierten Details aller lokalen Erklärungen aggregiert, muss somit eine globale Erklärung gefunden werden. Dieser Schritt wird in der vorliegenden Arbeit als **Globalisierung** bezeichnet². Wie in Abschnitt 3.3.4 definiert, ist das Ziel der Analyse die Erzeugung einer ‚Wenn-Dann‘-Regel r . Die Globalisierung übernimmt somit die Aufgabe, aus einer Menge lokaler Erklärungen, die in Form von Bildern vorliegen, eine mathematische Implikation abzuleiten. Dieser Prozess wird in vier Schritte unterteilt:

1. **Extraktion:** Festlegen einer Merkmalsmenge und Extraktion von Bildinformation aus den sichtbaren Superpixeln anhand dieser Merkmale.
2. **Aggregation:** Zusammenfassung und Überführung der extrahierten Information in einen logischen Ausdruck.
3. **Reduktion:** Entfernen redundanter Information innerhalb des Ausdrucks und Vereinfachung durch Quantisierung.
4. **Regelerzeugung:** Transformation des Ausdrucks in eine Implikation.

Extraktion. Das Finden von Bildinformation in den sichtbaren Superpixeln, die über die verschiedenen lokalen Erklärungen hinweg semantisch vergleichbar ist, ist eine Voraussetzung für die Bestimmung eines globalen Kriteriums für Prozesserverfolg. Die Autoren von LIME [223] formulieren diesen Aspekt im Kontext von Bilddaten als noch offenes Problem, geben aber einen Hinweis darauf, dass bestimmte Merkmale der Superpixel dafür hilfreich sein können. In Übereinstimmung mit dieser Anregung wird in der vorliegenden Arbeit die Problemstellung durch die Integration von Domänen- und Prozesswissen gelöst. Innerhalb der sichtbaren Bildregionen (Superpixel) lokaler Erklärungen können mit Hilfe von Methoden aus dem Computersehen bekannte Objekte eines Prozesses gesucht werden. Dies sind beispielsweise Werkstücke, die in eine Aufgabe involviert sind,

²Entgegen zu der hier gewählten Bezeichnung wird der Schritt in im Kontext der Arbeit entstandenen Publikationen ‚Generalisierung‘ (engl. *generalization*) genannt [81, 85, 86]. Aufgrund der potenziellen Mehrdeutigkeit des Begriffs [151] wird der Schritt in dieser Arbeit zu Gunsten der Klarheit umbenannt.

oder aber auch andere Objekte, wie Werkzeuge, oder weitere prozessspezifische Gegenstände. Pixelmengen bzw. Bildregionen werden somit konkreten Objekten zugewiesen. Diese Objekte können dann über alle Bilder hinweg analysiert werden. Dabei müssen zwei Aspekte berücksichtigt werden:

- (1) Es reicht nicht aus, lediglich das Auftreten von Objekten in den Bildern zu analysieren, sondern es müssen auch die Objektmerkmale betrachtet werden. Beispielsweise kann die Position eines Objekts im Zusammenhang mit dem Prozesserfolg stehen (Abschnitt 4.3.1). Für die Experimente in dieser Arbeit werden die gängigen Objektmerkmale Farbe, Form, Größe und Position (Schwerpunkt) verwendet. Dafür wird jedes Objekt, das in einer lokalen Erklärung $g(v)$ sichtbar ist, anhand dieser Merkmalsmenge analysiert. Die Entscheidung, diese Merkmale zu verwenden, wird durch Szenarien aus dem Fertigungsbereich motiviert, findet jedoch auch in verschiedenen anderen Feldern Anwendung, einschließlich, jedoch nicht beschränkt auf Robotik und Gesundheitswesen [65, 67, 226]. Dabei ist die Wahl der Merkmale nicht limitiert, sodass beliebige domänenspezifische Merkmale berücksichtigt werden können. Die Einbeziehung komplexerer Merkmale beeinträchtigt die Funktionsweise des Ansatzes nicht. Lediglich Anpassungen der Bildverarbeitungsmethoden zur Objekterkennung und Merkmalsextraktion sind erforderlich, um den Herausforderungen komplexerer Merkmale gerecht zu werden.
- (2) Sind die Objekte in Bildern eindeutig identifizierbar (z.B. anhand ihrer Merkmale oder durch Marker), liefert der Extraktionsschritt eine Tabelle mit $n \cdot |M|$ Spalten. Dabei ist n die Anzahl der verschiedenen Objekte, die innerhalb aller lokalen Erklärungen auftreten und M die Merkmalsmenge, die pro Objekt betrachtet wird. Zu jeder lokalen Erklärung wird ein Eintrag in dieser Tabelle erzeugt. Gilt wie in den Experimenten z.B. $|M| = 4$ mit $M = \{m_1, m_2, m_3, m_4\}$, wird Objekt i in der Tabelle durch $O_i = (m_1^i, m_2^i, m_3^i, m_4^i)$ beschrieben und umfasst vier aufeinanderfolgende Spalten. Zu Beginn der Extraktion wird festgelegt, welches O_i ein Objekt aus der Arbeitsumgebung abbildet und für den Analyseschritt nicht mehr verändert. Tritt ein Objekt in einer lokalen Erklärung nicht auf, bleiben die Einträge zugehöriger Spalten leer.

In bestimmten Szenarien sind Objekte anhand ihrer erfassten Merkmale nicht eindeutig unterscheidbar oder identifizierbar. Insbesondere kann es zu Unklarheiten kommen, wenn zwei Objekte mit identischen Merkmalen auftreten, beispielsweise wenn beide die gleiche Farbe, Form und Größe aufweisen (Szenario 2, Abschnitt 4.3.2.2). In solchen Fällen ist visuell nicht eindeutig bestimmbar, welches der beiden Objekte einer bestimmten Entität in einem gegebenen Bild entspricht. Folglich ist unklar,

Objekt 1				Objekt 2				...	Objekt n			
Farbe	Form	Gr.	Pos.	Farbe	Form	Gr.	Pos.	...	Farbe	Form	Gr.	Pos.
Rot	Rund	10	80	-	-	-	-	-	-	-	-	-
-	-	-	-	Rot	Rund	10	80	-	-	-	-	-
		
-	-	-	-	-	-	-	-	-	Rot	Rund	10	80

Tabelle 4.2: Zu einem Beispielbild $g(v)$ erzeugte Einträge. Durch die Permutation der Zuweisung des Bildobjekts zu n möglichen Objekten der Tabelle entstehen $\binom{n}{1} = n$ Einträge.

welche Spalten in der zu den lokalen Erklärungen erzeugte Tabelle mit welchen Werten gefüllt werden müssen. Falsche Zuordnungen führen zu einer nicht korrekten Abbildung der Realität und somit fehlerhaften Analyseergebnissen. Um diese Problemstellung zu adressieren, werden in der Tabelle alle möglichen Zuordnungskombinationen der k Objekte eines Bilds zu den n Objekten der Tabelle eingefügt. So werden für jede lokale Erklärung $\binom{n}{k}$ Einträge in der Tabelle erzeugt. Tabelle 4.2 zeigt einen Ausschnitt einer solchen Zuordnungspermutation mit vereinfachten, eindimensionalen Objektmerkmalen. Dieser Vorgang ermöglicht die Identifikation relevanter Merkmale unabhängig von Fehlern, die durch falsche Zuordnungen auftreten können. Außerdem können so alle Objekte gleichermaßen auf der Merkmalsebene miteinander verglichen werden.

Das Ergebnis des Extraktionsschritt ist somit eine Tabelle, die alle möglichen Merkmalsausprägungen enthält, die zu Prozesserfolg führen. Damit überführt dieser Schritt unstrukturierte Bilddaten in eine strukturierte Form, auf Basis derer in den nächsten Schritten allgemeingültige Aussagen abgeleitet werden können. Zur breiteren Abdeckung potenzieller Szenarien und Herausforderungen werden die nachfolgenden Schritte anhand der komplexeren Variante mit allen Zuordnungspermutationen erläutert.

Aggregation. Alle Zeilen der aus dem vorherigen Schritt resultierenden Tabelle werden in einen gemeinsamen logischen Ausdruck überführt. Dabei werden alle Einträge einer Zeile mit einem logischen ‚und‘ (\wedge) und Zeilen untereinander mit einem logischen ‚oder‘ (\vee) verknüpft. Beispielsweise beschreibt der Ausdruck $(O_{1_Farbe} = 'Rot' \wedge O_{1_Form} = 'Rund' \wedge O_{1_Gr.} = '10' \wedge O_{1_Pos.} = '80') \vee \dots \vee (O_{n_Farbe} = 'Rot' \wedge O_{n_Form} = 'Rund' \wedge O_{n_Gr.} = '10' \wedge O_{n_Pos.} = '80')$ den Inhalt aus Tabelle 4.2. Dem Beispiel folgend entsteht ein großer Ausdruck, der alle extrahierten Informationen umfasst. Dieser Ausdruck kann als Formulierung der Bedingung betrachtet werden, die erfüllt sein muss, um Prozesserfolg zu erreichen. Anschließend erfolgt eine Zusammenfassung der logischen Bedingungen, die keine zusätzliche Information liefern, da sie bereits durch andere Teilausdrücke repräsentiert sind. Dies wird durch Anwendung des zweiten Absorptionsgesetzes aus der

Aussagenlogik ‚ $A \vee (A \wedge B) = A$ ‘ vollzogen [36]. Dadurch bleiben genau die Teilausdrücke übrig, die erfüllt sein müssen, damit der Gesamtausdruck gilt.

Reduktion. Grundsätzlich eignet sich der nun vorliegende Gesamtausdruck als Basis zur Erzeugung von r , da dieser nun bzgl. der Eingabedaten lediglich relevante Informationen zu Objekten für die betrachte Aufgabe enthält. Es ist jedoch möglich, dass er zu diesem Zeitpunkt noch redundante Objektmerkmale enthält. Dem obigen Beispiel folgend könnte die Farbinformation ‚Rot‘ irrelevant sein, wenn für die Aufgabe grundsätzlich nur rote Objekte zur Verfügung stehen. Um solche redundanten Informationen zu entfernen, wird der mögliche Wertebereich jedes Merkmals eines Objekts im Kontext der Aufgabe berechnet. Dafür wird zunächst im Gesamtausdruck durch die Anwendung des Distributivgesetzes aus der Aussagenlogik ‚ $(A \wedge B) \vee (A \wedge C) = A \wedge (B \vee C)$ ‘ vereinfacht [36]. Der reduzierte Ausdruck enthält dann Teilausdrücke der Form $m_j^i = w_1 \vee \dots \vee m_j^i = w_l$, wobei m_j^i das j -te Merkmal des i -ten Objekts beschreibt und w_1, \dots, w_k Ausprägungen von m_j^i . Falls dann $\{w_1, \dots, w_k\}$ alle im Aufgabenkontext möglichen Ausprägungen W_j^i von m_j^i abdeckt, ist der Teilausdruck immer wahr, somit eine Tautologie und kann gekürzt werden. Um W_j^i zu bestimmen, werden alle Eingabebilder (positiv und negativ gelabelte Daten) betrachtet und für jedes Bild die dort auftretenden Objekte anhand der Merkmale M analysiert.

Weiter können im Rahmen des Reduktionsschritts Werte numerischer Merkmale (z.B. Position oder Größe) durch Quantisierungsmethoden in Intervalle zusammengefasst werden. Dabei kann die Größe der Intervalle als auch die Bedingung, wann Werte in ein Intervall zusammengeführt werden, beliebig gewählt werden und sollte von ProzessexpertInnen definiert werden. Als Beispiel wird ein Ausdruck betrachtet, der zwei Teilausdrücke enthält, die bis auf ihren Positionswert identisch sind: $(O_{1_Farbe} = 'Rot' \wedge O_{1_Form} = 'Rund' \wedge O_{1_Gr.} = '10' \wedge O_{1_Pos.} = '80') \vee (O_{1_Farbe} = 'Rot' \wedge O_{1_Form} = 'Rund' \wedge O_{1_Gr.} = '10' \wedge O_{1_Pos.} = '60')$. Dann können diese durch Quantisierung in den Ausdruck $(O_{1_Farbe} = 'Rot' \wedge O_{1_Form} = 'Rund' \wedge O_{1_Gr.} = '10' \wedge O_{1_Pos.} \in '[60, 80]')$ zusammengefasst werden. Der Reduktionsschritt vereinfacht den Ausdruck durch Eliminieren redundanter Informationen, was für die Erfüllung der Anforderungen aus Abschnitt 1.2.1 von Bedeutung ist. Außerdem unterstützt dieser Prozess später die effiziente Erstellung einer Aufgabenannotation, da weniger Information berücksichtigt werden muss. Abschließend ist zu betonen, dass die obigen Schritte auf alle durch Permutation entstanden Teilausdrücke gleichermaßen angewendet werden.

Regelerzeugung. Das Ergebnis des Reduktionsschritts kann als Ergebnis einer unstrukturierten Datenanalyse r_{ud} betrachtet werden. Die relevanten Details werden dabei in Form eines logischen Ausdrucks beschrieben. Genauer hat r_{ud} an dieser Stelle die Form $r_{ud} = A_1 \vee \dots \vee A_p$, wobei A_i einem Ausdruck entspricht, der durch Aggregation und Reduktion die Information eines oder mehrerer Bilder zusammenfasst ($i = 1, \dots, p$).

Seien O_{i_1}, \dots, O_{i_k} alle Objekte, die in A_i referenziert werden. Dann müssen auch alle $\binom{n}{k} - 1$ -Ausdrücke, die aus A_i entstehen, wenn O_{i_1}, \dots, O_{i_k} durch beliebige Kombinationen der Objekte O_1, \dots, O_n ersetzt wird, in $\{A_1, \dots, A_p\}$ enthalten sein. Alle diese $\binom{n}{k}$ Ausdrücke können zusammengefasst werden in einen Ausdruck der Form $\exists \tilde{O}_1, \dots, \tilde{O}_k : \tilde{A}_i$ wobei \tilde{A}_i dem Ausdruck A_i entspricht, in dem O_{i_j} durch \tilde{O}_j ersetzt ist ($j = 1, \dots, k$). Informell bedeutet dies, dass die Teilausdrücke, zu denen noch die permutierten Varianten existieren, zusammengefasst werden. Damit wird der Ausdruck verallgemeinert und von konkreten Objektzuordnungen gelöst. Dies entspricht dann sinngemäß der Aussage ‚Es existieren Objekte mit den Eigenschaften ...‘. Sind beispielsweise alle Zuordnungspemutationen zum Beispielausdruck von oben vorhanden, können diese in den Ausdruck $\exists O_i(\text{Farbe} = \text{Rot}' \wedge \text{Form} = \text{Rund}' \wedge \text{Gr.} = \text{10}' \wedge \text{Pos.} \in' [60, 80]')$ überführt werden. Auf Basis dieser Repräsentation kann nun die erwünschte Regel $r = \text{,}X \Rightarrow Y\text{'}$ abgeleitet werden. Dafür wird der erzeugte Ausdruck als linke Seite X der Implikation gesetzt. Die Regel ist dann so zu verstehen, dass die Erfüllung aller Bedingungen auf der linken Seite bei der Ausführung von a zu Prozesserfolg führt.

Eine abgeleitete Regel entspricht für die hier entwickelte Methode der Schnittmenge lokaler Erklärungen, welche wiederum auf linearen Abtastungen der Entscheidungsgrenze des trainierten CNNs basieren. Der Ansatz wird auf den beiden entworfenen Szenarien (Abschnitt 4.3.2) angewendet und die Ergebnisse im nächsten Abschnitt vorgestellt.

4.4.4 EXPERIMENTE UND EVALUATION

Für die Implementierung³ des Analyseschritts wird für das verwendete CNN eine Standard-Netzarchitektur bestehend aus drei Faltungsschichten gewählt. Dieser Aufbau und zugehörige Parametrierung folgt der Umsetzung in [283]. Für die Konfiguration von LIME sind die zwei Hyperparameter n_{features} und n_{samples} hervorzuheben:

- Der Hyperparameter n_{features} beschreibt die maximale Anzahl von Bildsegmenten, die in der Erklärung berücksichtigt werden sollen. Dieser Hyperparameter ist entscheidend für nützliche und interpretierbare Ergebnisse. Die Berücksichtigung zu vieler Merkmale führt zu Unsicherheiten hinsichtlich der Identifikation der Segmente, welche für die Klassifikation tatsächlich relevant sind. Andererseits werden bei Auswahl eines zu niedrigen Werts nicht alle wichtigen Segmente hervorgehoben. Für beide Szenarien wird der Hyperparameter zunächst auf den Wert 10 festgelegt.
- Die Anzahl der Beispielinstanzen, die von LIME verwendet werden, um eine lokale Erklärung zu generieren, wird durch n_{samples} definiert. Höhere Werte erzeugen mehr

³Die Implementierung ist online zu finden: https://github.com/MyFi-UBT/thesis_implementation, zuletzt besucht: 01.03.2024.

Beispiele und eine genauere Erklärung auf Kosten der Rechenzeit. Der Wert wird für beide Szenarien auf 1000 festgelegt.

Für jedes Szenario aus Abschnitt 4.3.2 werden 1000 Bilder generiert. Darunter erfüllen 500 Bilder das definierte Kriterium und sind positiv gelabelt, während die anderen 500 Bilder negativ gelabelt sind. Aus dem Datensatz wird eine Teilmenge für die Validierung des CNN genutzt, um die Genauigkeit der Klassifizierung zu überprüfen. Dabei werden 80% der Eingabedaten für das Training des Netzes und 20% zur Validierung genutzt. Die Selektion erfolgt gleichmäßig bzgl. beider Klassen der Daten. Das Training des CNNs wird so lange durchgeführt, bis der Loss einen ausreichend niedrigen Wert (< 0.01) und die Accuracy einen ausreichend hohen Wert ($> 99\%$) erreichen.

Zur Beurteilung des Erfolgs des implementierten Ansatzes wird die Ausgabe des Globalisierungsschritts betrachtet. Dafür wird geprüft, ob die Ergebnisse die in den Bilddaten versteckten relevanten Prozessdetails enthalten. Die Repräsentation in Form einer Regel ist für die Bewertung der Effektivität nicht relevant, weshalb der Globalisierungsschritt für die Experimente in einer vereinfachten Variante implementiert wird. Diese umfasst lediglich den Extraktionsschritt und einen vereinfachten Aggregationsschritt. Da sich die Objekte deutlich vom Hintergrund unterscheiden, werden die Bilder anhand der Farbe der einzelnen Pixel segmentiert. Dies ist eine weitverbreitete und einfache Methode, um Objekte in Bilddaten zu erkennen [248]. Pixel, welche die Hintergrund haben, werden somit ignoriert. Aus den so übrig gebliebenen Pixeln pro Objekt, sog. *Blobs*, werden anschließend Form, Größe und Position (Schwerpunkt der Pixelkoordinaten) eines Objekts bestimmt. Größe und Position können direkt berechnet werden, für die Interpretation der Form wird der Implementierungsansatz *ShapeDetector* des OpenCV-Pakets [44] verwendet. Weiter ist die Implementierung auf die Analyse eines Objekts im Bild beschränkt. Daher umfasst sie bzgl. des Aggregationsschritts lediglich das Zusammenfassen der auftretenden Werte eines Objektmerkmals.

4.4.5 ERGEBNISSE

Die Ergebnisse des implementierten Analyseschritts beider Szenarien zeigt Tabelle 4.3. Einerseits sind die analysierten Werte für die betrachteten Objektmerkmale, nämlich Position, Größe, Form und Farbe, aufgeführt. Andererseits sind für die numerischen Merkmale (Position und Größe) die Anzahl der verschiedenen auftretenden Werte angegeben, während für die übrigen Merkmale (Form und Farbe) die Häufigkeit der jeweiligen Werte erfasst ist. In den folgenden Abschnitten werden die Ergebnisse pro Szenario nacheinander ausführlich betrachtet und diskutiert.

4.4.5.1 ERGEBNISSE ZU SZENARIO 1

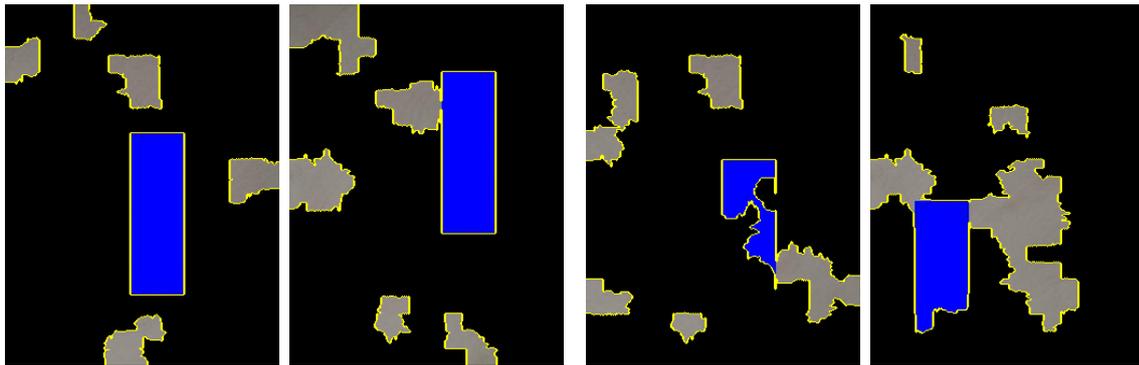
Insgesamt werden in Szenario 1 durch die Analyse der lokalen Erklärungen 497 verschiedene Objektpositionen identifiziert, die sich in den Pixelbereichen 26 bis 229 in x-Richtung und 74 bis 259 in y-Richtung erstrecken. Des Weiteren werden 40 verschiedene Objektgrößen festgestellt, wobei die Breite der Objekte bis zu 3 Pixel und die Höhe bis zu 40 Pixel variiert. Die Formen umfassen runde, dreieckige, rechteckige und fünfeckige Strukturen, wobei alle Objekte die Farbe ‚Blau‘ aufweisen.

Das Analyseergebnis zeigt, dass das relevante Prozessdetail ‚Farbe = Blau‘ gefunden wird. Diese Beobachtung belegt die Effektivität des Ansatzes für das vorliegende Szenario. Auffällig sind jedoch die verschiedenen Objektgrößen und -formen, die neben dem erwarteten Wert (50, 150) (definierte Größe des Objekts) und ‚rechteckig‘ auftreten. Um die Ursache dieser Einträge zu identifizieren, ist eine nähere Betrachtung der von LIME erzeugten lokalen Erklärungen hilfreich. Beispiele lokaler Erklärungen sind in [Abbildung 23](#) dargestellt. Für die Erklärung irrelevante Segmente des Eingabebilds sind geschwärzt. Relevante Segmente sind gelb umrahmt und behalten Farben des Eingabebilds.

Den lokalen Erklärungen ist zu entnehmen, dass die Entscheidung des CNNs stark von dem in der Szene enthaltenen Objekt und seinen Eigenschaften abhängt. Allerdings sind auch Segmente hervorgehoben, die große Bereiche des Hintergrunds enthalten. Beispiele dazu zeigt [Abbildung 23a](#), denen ein Großteil der lokalen Erklärungen ähnelt (77% aller Bilder). In dem zugrundeliegenden Implementierungsansatz werden Pixel, welche die Hintergrundfarbe haben, ignoriert. Dadurch werden Segmente, die lediglich Teile des Hintergrunds zeigen, nicht ausgewertet und damit nicht in die Ergebnismenge aufgenommen. Der Ansatz verhindert damit potenzielle Fehler für Szenario 1, da hier der Hintergrund irrelevant ist. Allerdings ist es im Kontext anderer Szenarien möglich, dass

	Szenario 1		Szenario 2	
<i>Merkmal</i>	Wert	Häufigkeit	Wert	Häufigkeit
Position	[(26,74),..., (229,259)]	497 versch. Einträge	[(29,28),..., (477,323)]	499 versch. Einträge
Größe	[(47,118),..., (50,150)]	40 versch. Einträge	[(55,58),..., (487,390)]	302 versch. Einträge
Form	Rund, Dreieckig, Rechteckig, Fünfeckig	33/1/443/23	Rund, Dreieckig, Viereckig, Rechteckig, Fünfeckig	372/11/13/36/68
Farbe	Blau	500	Rot	500

Tabelle 4.3: Analyseergebnisse beider Szenarien zu den Experimenten mit $n_{\text{features}} = 10$.



(a) Das Objekt ist vollständig, zusammen mit Teilen des Hintergrund hervorgehoben.

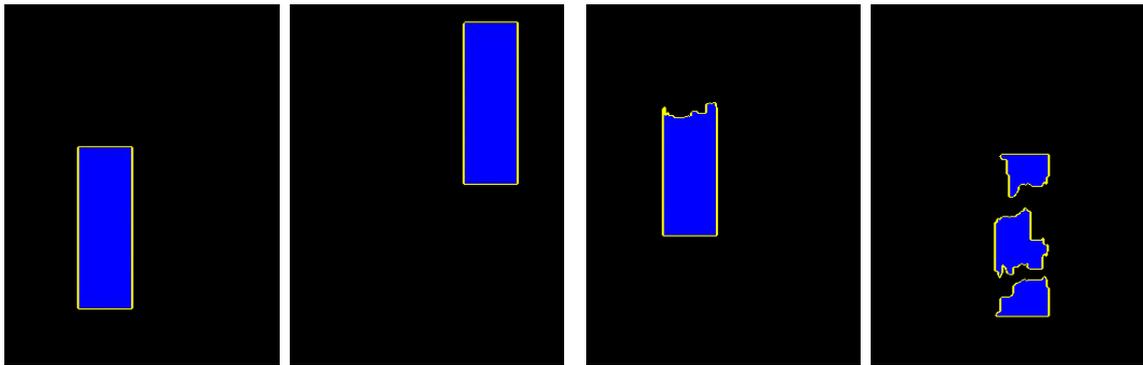
(b) Das Objekt ist nicht vollständig in einem Segment erfasst und hervorgehoben.

Abbildung 23: Lokale Erklärungen zu Szenario 1 mit $n_{\text{features}} = 10$, angelehnt an [85].

Bereiche des Hintergrunds für Prozesserfolg eine Rolle spielen. Außerdem ist der Hintergrund in komplexeren Bildern nicht immer eindeutig von den Objekten trennbar, weshalb dieses Ergebnis kritisch zu betrachten ist. In den restlichen lokalen Erklärungen sind außerdem nur Teile des Objekts hervorgehoben (vgl. Abbildung 23b). Auf derartige Bilder sind die Abweichungen der Ergebnisse bzgl. der Objektform und -größe zurückzuführen. Für Szenario 1 werden die beiden Merkmale im Rahmen des Globalisierungsschritts aus der Ergebnismenge entfernt, da nur rechteckige Objekte mit der Größe 50×150 auftreten (Abschnitt 4.4.3). Dagegen kann dies in anderen Aufbauten zu fehlerhaften Ergebnissen führen. Diese können dann irrelevante oder sogar falsche Prozessdetails enthalten.

Zur Untersuchung dieser problematischen Beobachtungen wird in einem weiteren Experimentdurchlauf eine andere Parametrisierung für LIME gewählt ($n_{\text{features}} = 4$ [85]). Damit können bzgl. des Hintergrunds deutlich bessere Ergebnisse erzielt werden. In 90% der Fälle ist kein Hintergrund zu sehen. Darunter ist in 23% das rechteckige Objekt vollständig hervorgehoben (vgl. Abbildung 24a). Diese Bilder entsprechen einem optimalen Ergebnis auf Basis derer die Analyse nur die erwarteten Ergebnisse liefert, sowie lediglich das Objekt als relevant für Prozesserfolg deklariert. Allerdings sind in 74% der Fälle ohne Hintergrund die Objekte nicht vollständig hervorgehoben. Abbildung 24b zeigt Beispiele solcher Ergebnisse. Vor allem Ergebnisse wie das rechte Bild führen weiterhin zu Abweichungen hinsichtlich der analysierten Objektformen und erfordern eine Optimierung der Segmentierung. Dieser Aspekt wird im Kontext von Szenario 2 behandelt.

Insgesamt zeigen die Ergebnisse, dass die entwickelte Methode in der Lage ist, dass relevante Prozessdetail für dieses Szenario zu identifizieren. Der Vergleich der Ergebnisse der beiden Experimentdurchläufe, in denen verschiedene Werte für den Hyperparameter n_{features} verwendet werden, liefert weitere Erkenntnisse. Dabei wird deutlich, dass dieser Hyperparameter einen starken Einfluss auf die Qualität der lokalen Erklärung nimmt. Eine



(a) Optimale Ergebnisse: Lediglich das Objekt ist zu sehen und vollständig hervorgehoben. (b) Lediglich das Objekt zu sehen, allerdings nicht vollständig hervorgehoben.

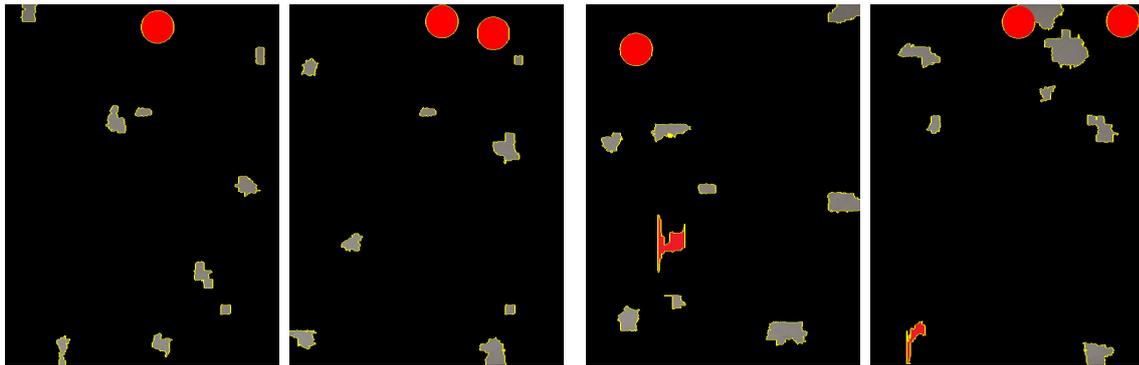
Abbildung 24: Lokale Erklärungen zu Szenario 1 mit $n_{\text{features}} = 4$, angelehnt an [85].

unangemessene Konfiguration, d.h. ein zu hoher Wert, ermöglicht einen zu großen Spielraum und führt zur Hervorhebung eigentlich irrelevanter Segmente. Diese Beobachtung gibt einen Hinweis auf Optimierungspotenziale von LIME bzw. geeigneten Konfigurationen für die entwickelte Methode. Dieser Aspekt wird im Zusammenhang mit komplexeren Beispielen in Abschnitt 6.4.3.2 näher untersucht.

4.4.5.2 ERGEBNISSE ZU SZENARIO 2

Die Ergebnisse zu Szenario 2 sind rechts in Tabelle 4.3 zusammengefasst. Zu diesem Szenario umfasst das gesuchte relevante Prozessdetail die Merkmale und Ausprägungen ‚Form = Rund‘ und ‚Position = Oberes Siebteil‘. Dabei werden vor allem diese Merkmale im Folgenden betrachtet.

Die Bilder sind 672 Pixel hoch, weshalb die analysierten Positionswerte mit $y < 323$ etwa die obere Bildhälfte abbilden. Damit ist auch der gesuchte Bereich, das obere Siebteil ($y \leq 96$), zwar enthalten, allerdings werden für 15% der Daten andere Positionen innerhalb der oberen Bildhälfte analysiert. Damit deklariert der Analyseschritt fälschlicherweise die komplette obere Bildhälfte als relevant. Weiter enthält die Ergebnismenge für die Objektform neben dem erwarteten Wert ‚Rund‘ auch noch weitere Werte. Für eine ausgiebigere Untersuchung dieses Ergebnisses werden erneut die lokalen Erklärungen betrachtet (vgl. Abbildung 25). Die Mehrheit der Erklärungen (64%) ähnelt den Bildern in Abbildung 25a und zeigt die effektive Filterung irrelevanter Bildinformation durch LIME. Dabei ist entweder ein rundes (linkes Bild) oder zwei runde Objekte (rechtes Bild) hervorgehoben. Dies zeigt, dass das CNN in Eingabebildern mit zwei runden Objekten im oberen Siebteil beide als relevant deklariert. Befindet sich nur ein rundes Objekt in diesem Bereich, wird nur dieses als relevant erachtet. Die rechteckigen Objekte sind nicht hervorgehoben,



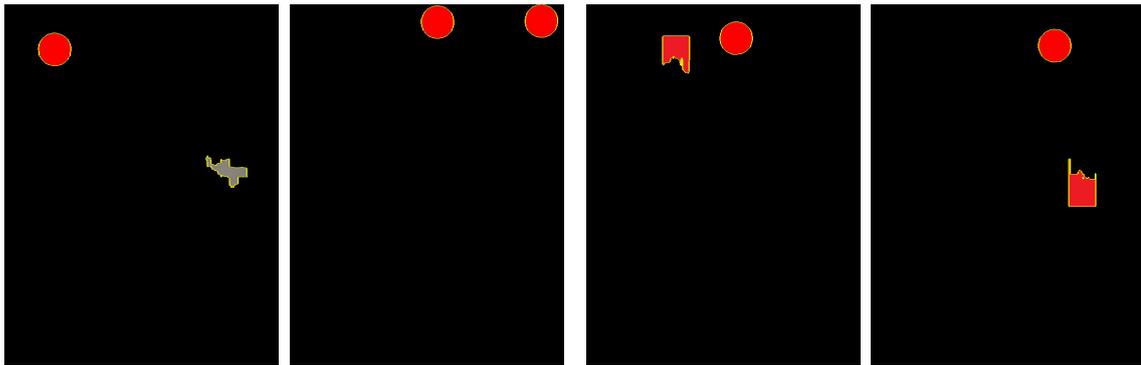
(a) Von den Objekten sind ausschließlich runde Objekte hervorgehoben.

(b) Sowohl runde Objekte, als auch Teile der rechteckigen Objekte sind hervorgehoben.

Abbildung 25: Lokale Erklärungen zu Szenario 2 mit $n_{\text{features}} = 10$, angelehnt an [85].

wodurch außerdem abzuleiten ist, dass lediglich die runden Objekte mit Prozesserfolg korrelieren. Für diese Menge lokaler Erklärungen analysiert die Methode korrekterweise, dass entweder ein rundes oder zwei runde Objekte im oberen Siebtel der Fläche platziert sein müssen. Betrachtet man ausschließlich diese Ergebnisse, kann das versteckte relevante Prozessdetail erfolgreich identifiziert werden. Damit kann der Ansatz für Szenario 2 und somit einem im Vergleich zu Szenario 1 komplexeren Aufbau effektiv angewendet werden. Allerdings sind in den restlichen lokalen Erklärungen (vgl. Abbildung 25b) neben den runden Objekten Teile der rechteckigen Objekte zu erkennen. Diese sind ursächlich für die abweichenden Werte der relevanten Merkmale Objektform und -position und führen dazu, dass der Analyseschritt das relevante Prozessdetail nicht vollständig identifiziert. Daneben verursachen sie die vielen verschiedenen und falschen Werte für die Objektgröße in Tabelle 4.3. Die Verringerung der fehlerbehafteten lokalen Erklärungen ist somit essenziell, weshalb ein weiterer Experimentdurchlauf mit einer anderen Konfiguration für n_{features} durchgeführt wird.

Die Reduktion des LIME-Hyperparameters ($n_{\text{features}} = 2$ [85]) verbessert auch in Szenario 2 die Ergebnisse deutlich (vgl. Abbildung 26). Darunter ist insbesondere den Beispielen in Abbildung 26a zu entnehmen, dass in einigen der lokalen Erklärungen aus dem vorherigen Experiment (vgl. Abbildung 25b) die hervorgehobenen Teile der rechteckigen Objekte verschwinden. Die Menge der Ergebnisse, in denen korrekterweise ausschließlich runde Objekte hervorgehoben sind, steigt auf 79%. Unter den restlichen fehlerbehafteten Erklärungen ist außerdem nur in vier Bildern ein Objektteil hervorgehoben, das sich nicht im oberen Siebtel der Szene befindet (vgl. rechtes Bild in Abbildung 25b). Im Vergleich zum vorherigen Experiment, in dem 84 solcher Bilder auftreten, verdeutlicht dies, dass das CNN die Präsenz eines Objekts im oberen Siebtel der Fläche im Zusammenhang mit Prozesserfolg wichtiger erachtet als an anderen Positionen. Diese Beobachtung liegt



(a) Verbesserte Ergebnisse der Szenen in Abbildung 25b. (b) Hervorgehobene Segmente umfassen weiterhin runde Objekte, sowie Teile anderer Objekte.

Abbildung 26: Lokale Erklärungen zu Szenario 2 mit $n_{\text{features}} = 2$, angelehnt an [85].

im Hyperparameter n_{features} begründet. Über diesen wird bestimmt, aus wie vielen Segmenten die Erklärung besteht (Abschnitt 4.4.4). Mit kleineren Werten für n_{features} werden weniger relevante Segmente nicht mehr hervorgehoben. Ein Herausfiltern dieser vier Ausreißer führt zu den gewünschten Ergebnissen hinsichtlich der Objektposition, sodass das obere Siebtel der Fläche als relevant deklariert wird. Wird außerdem die Analyse insgesamt ohne die fehlerbehafteten Erklärungen erneut durchgeführt, identifiziert sie zudem korrekterweise ausschließlich runde Objekte.

Zusammenfassend zeigt sich die entwickelte Methode auch für Szenario 2 als effektiv. Dabei ist die Konfiguration des Hyperparameters n_{features} auch in diesem Szenario entscheidend für die Qualität der Ergebnisse, weshalb Unterstützung bei seiner Bestimmung erforderlich ist (Abschnitt 6.4.3.2). In diesem Kontext ist ein weiterer Aspekt zu erwähnen, der die Ergebnisqualität beeinflusst. Die Objekte in den in [85] publizierten Experimenten sind größer als die in diesem Aufbau verwendeten Objekte. Im Vergleich ist zu beobachten, dass hier die entscheidenden Objekte (z.B. die runden Objekte in Szenario 2) immer vollständig hervorgehoben sind. Dagegen sind in einigen der lokalen Erklärungen in [85] die Objekte nur teilweise zu sehen. Dies deutet darauf hin, dass der Segmentierungsschritt von LIME für bestimmte Objektformen und -größen besser geeignet ist. Dadurch wird ein weiteres Optimierungspotenzial bzgl. der Segmentierung von LIME aufgedeckt. Weitere Untersuchungen hinsichtlich dieses Aspekts finden sich ebenfalls in Abschnitt 6.4.3.2. Insgesamt wird durch die Experimente zu beiden Szenarien belegt, dass die Anwendung von LIME zur Umsetzung des Analyseschritts für unstrukturierte Bilddaten zielführend ist. In Abschnitt 4.6 wird dies noch einmal durch den Vergleich mit einer alternativen Umsetzungsmethode diskutiert.

4.5 ANALYSE STRUKTURIERTER BILDDATEN MIT DATA MINING

Neben den im vorherigen Unterkapitel diskutierten Ansätzen zur Analyse unstrukturierter Daten, gibt es eine Vielzahl von Verfahren zur Analyse strukturierter Daten. Die Verfahren lassen sich dabei allgemein dem Konzept des **Data Mining** zuordnen. Data Mining befasst sich mit der Identifizierung von Mustern und Zusammenhängen in Datenbeständen und stellt einen integralen Bestandteil des Prozesses zur Extraktion von Wissen aus Daten dar. Die breite Anwendbarkeit und die unterschiedlichen Schwerpunkte der verschiedenen Methoden untermauern die Wahl eines Data Mining Ansatzes als Lösung für die Problemstellung dieser Arbeit.

4.5.1 EINFÜHRUNG IN KDD UND DATA MINING

Konzepte und Werkzeuge zur **Wissensentdeckung in Datenbeständen** (engl. *knowledge discovery in databases*) (KDD) unterstützen Menschen und Organisationen in der Extraktion nutzvoller Information bzw. Wissen aus (großen) Mengen digitaler Daten [78]. Dabei besteht der KDD-Prozess aus mehreren Teilschritten [43], die in Abbildung 27 zusammengefasst sind.

Zunächst wird das Ziel des KDD-Prozesses im Systemkontext definiert und damit die Fragestellung formuliert, die durch die Daten beantwortet werden soll. Diese kann vielfältige Aspekte umfassen, wie z.B. die Vorhersage zukünftiger Ereignisse oder das tiefere Verständnis eines Systems durch die Aufdeckung von komplexen Zusammenhängen in

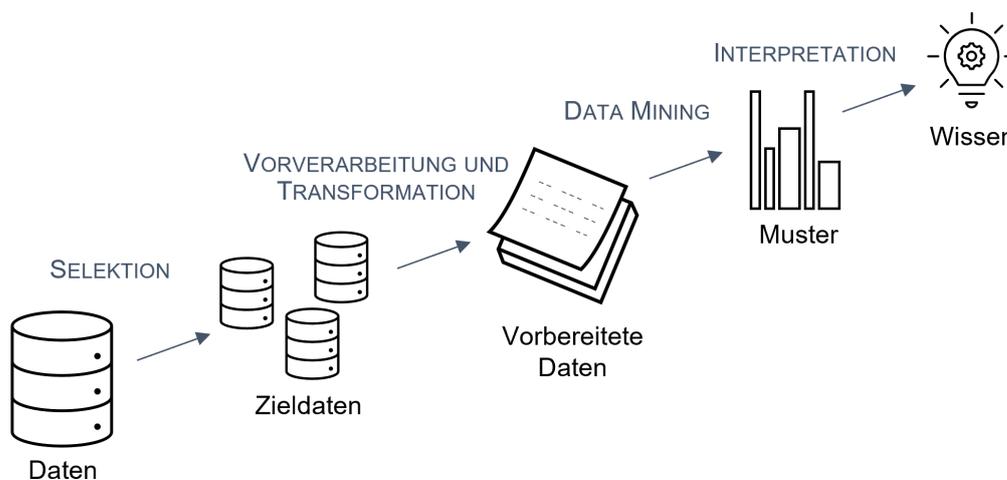


Abbildung 27: Übersicht des KDD-Prozesses, orientiert an [78].

den vorhandenen Daten. Anschließend wird aus einer Menge von Daten eine Auswahl getroffen, die für das definierte Ziel einer eingehenden Analyse unterzogen werden soll (,Selektion‘). Die Daten werden anschließend aufbereitet und in ein für die Analyse passendes Format überführt (,Vorverarbeitung und Transformation‘). Dieser Schritt beinhaltet das Entfernen von Störfaktoren oder anderen bereinigenden Operationen, aber auch die Reduktion der Dimension der Daten. Dazu gehören beispielsweise auch Maßnahmen zur Strukturierung unstrukturierter Daten [208]. In existierenden Arbeiten wird der Schritt in Form von zwei separaten Schritten betrachtet [78]. Diese werden hier jedoch aus Gründen der Vereinfachung zusammengefasst. Anschließend erfolgt der Kernschritt des Prozesses durch Data Mining. Dafür wird zunächst eine zum Datenkontext und der Zielsetzung angemessene Methode ausgewählt. An dieser Stelle wird entschieden, welche Modelle und Parameter für die Umsetzung der Ziele geeignet sind (z.B. Klassifizierung oder Regression) und welche Data Mining-Methode dazu passt. Diese wird angewendet und interessante Muster in Form von bestimmten Darstellungsarten repräsentiert, wie z.B. durch Klassifizierungsregeln oder Entscheidungsbäume. Abschließend werden die gefundenen Muster evaluiert, aufbereitet und visualisiert (,Interpretation‘). Dabei ist eine Rückkehr zu einem der vorherigen Schritte für weitere Iterationen möglich. Das so aus den Daten neu gewonnene oder entdeckte Wissen wird in den ursprünglichen Systemkontext entweder direkt zurückgeführt oder für zukünftige Aktionen in anderen Systemen genutzt.

Obwohl Data Mining als Teilschritt des KDD-Prozesses definiert ist, wird der Begriff in der Literatur häufig stellvertretend für den gesamten Prozess verwendet [294]. Diese Beobachtung unterstreicht die herausragende Bedeutung von Data Mining und betont die zentrale Rolle der ausgewählten Methodik im Rahmen des gesamten Prozesses. Data Mining findet in vielen Bereichen Anwendung, so zum Beispiel im Marketing, in der Produktion und Fertigung, im Finanzwesen, in der Telekommunikation oder in der Medizin [158]. Dabei wird Data Mining entweder zur **Vorhersage** zukünftigen Systemverhaltens (engl. *predictive data mining*) oder zur **Beschreibung** eines Systems (engl. *descriptive data mining*) genutzt [213]:

- Vorhersage-Methoden fokussieren sich auf ein bestimmtes Attribut (engl. *target attribute*). Angesichts einer Anzahl von Instanzen in einem Datensatz, bei denen der Wert des Zielattributs bekannt ist, wird ein Vorhersage-Modell erstellt. Dieses Modell soll in der Lage sein, den Wert für neue Instanzen vorherzusagen.
- Deskriptives Data Mining umfasst dagegen die Suche eines Modells, das interessante Muster innerhalb der betrachteten Daten beschreibt. Dies schließt Modelle mit ein, die beispielsweise durch Wahrscheinlichkeitsabhängigkeiten zwischen Attributen oder in Form von Assoziationen zwischen Attributen repräsentiert werden können.

In dieser Arbeit liegt der Fokus insbesondere auf deskriptiven Data Mining-Methoden. Diese finden Modelle, die das Verhalten eines Systems anhand von Daten beschreiben und transparent machen. Solche Modelle können als Erklärung herangezogen werden, um auf Basis komplexer Zusammenhänge in Prozessdaten, Ursachen für Prozesserverfolg (oder Prozessfehlschlag) zu bestimmen. Prognosen des Systemverhaltens und damit präskriptive Ansätze reichen dafür nicht aus und genügen damit nicht den Anforderungen der vorliegenden Problemstellung. Einer der bekanntesten deskriptiven Ansätze für strukturierte Daten ist das Finden von Assoziationsregeln durch **Association Rule Mining**⁴ [143]. Diese Technik wird in dieser Arbeit zur Extraktion relevanter Prozessdetails eingesetzt. Dabei ist diese Entscheidung durch folgende Aspekte motiviert.

Regelerzeugung: Die Ausgabe von Association Rule Mining sind Regeln, welche die Beziehungen zwischen verschiedenen Variablen in den Daten beschreiben. Diese Regeln bieten klare Einsichten in komplexe Zusammenhänge und haben sich vor allem im Kontext von Prozessen als effektiv erwiesen (Abschnitt 2.1.2). Außerdem erfüllen sie bereits das vom Gesamtkonzept geforderte Format für die aus dem Analyseschritt resultierende Regel r .

Eignung für strukturierte Bilddaten: In bestehenden Arbeiten findet Association Rule Mining für verschiedene Problemstellungen und Daten Anwendung. Darunter hat sich die Technik auch im Kontext von Bilddaten und für Klassifikationsprobleme als effektiv erwiesen [65, 66, 77]. Sie zeichnet sich darüber hinaus durch ihre Fähigkeit aus, große Datenmengen zu bewältigen [277]. Bei der Extraktion relevanter Informationen aus Bilddaten ist es erforderlich, eine große Anzahl von Merkmalen innerhalb eines Bilds zu betrachten. Association Rule Mining stellt in diesem Zusammenhang keinen limitierenden Faktor dar, was von besonderer Bedeutung für die vorliegende Arbeit ist.

Umfangreiche Forschung: Association Rule Mining ist eine der wichtigsten und meist erforschten Techniken aus dem Bereich Data Mining [294]. Aus diesem Grund hat sich eine Vielzahl von Algorithmen entwickelt, die hinsichtlich ihrer Effektivität und Leistung in [116, 149] zusammengefasst und evaluiert werden. Die breite Palette verfügbarer Algorithmen erleichtert die Auswahl eines geeigneten Ansatzes für die Implementierung des Analyseverfahrens und unterstützt die Evaluation der Ergebnisse.

⁴Der Begriff ‚Association Rule Mining‘ ist ein feststehender Begriff in der Wissenschaft und wird in der Arbeit mit seinem englischen Terminus verwendet.

4.5.2 ASSOCIATION RULE MINING

Association Rule Mining ist ein regelbasierter Ansatz, der die Entdeckung von Korrelationen, Assoziationen oder häufigen Mustern zwischen Attributen in Datenbanken ermöglicht [143]. Das Ergebnis sind **Assoziationsregeln** (engl. *association rules*), die wie folgt definiert sind [14]. Sei $I = I_1, I_2, \dots, I_m$ eine Menge von m eindeutigen Attributen (im Folgenden als *Items* bezeichnet), $T \subseteq I$ eine Transaktion, die eine Menge von Items enthält und D eine Datenbank mit mehreren Transaktionen. Eine Assoziationsregel hat die Form $X \Rightarrow Y$ mit $X \cap Y = \emptyset$ und $X, Y \neq \emptyset$. Dabei sind $X, Y \subset I$ Mengen von Items (in dieser Arbeit dem englischen Fachbegriff folgend als *Itemsets* bezeichnet) wobei X als **Antezedent** und Y als **Konsequent** einer Regel bezeichnet werden.

4.5.2.1 ANWENDUNGSGEBIETE UND ALGORITHMEN

Association Rule Mining kommt in verschiedenen Domänen und für unterschiedliche Problemstellungen zum Einsatz. Darunter ist das Finden von Assoziationsregeln erstmalig im Einzelhandel zur Warenkorbanalyse eingeführt worden [13]. Dort sind Assoziationsregeln genutzt worden, um das Einkaufsverhalten von Kunden basierend auf einer großen Sammlung an Einkaufsdaten zu bestimmen. Als Beispiel enthalten dort gefundene Assoziationsregeln die Aussage, dass 90% der Transaktionen oder Einkäufe, in denen Brot und Butter gekauft wurden, auch Milch gekauft wurde. In diesem Zusammenhang ist außerdem der erste Association Rule Mining-Algorithmus, der ‚AIS‘-Algorithmus, eingeführt worden [294]. Dieser generiert sog. ‚Kandidaten‘ (engl. *candidate generation*) basierend auf häufig auftretenden Itemsets (engl. *frequent itemsets*) in den Daten. In mehreren Durchläufen und durch wiederholtes Scannen der Datenbank werden die Kandidaten erweitert und der Zusammenhang verschiedener Items bestimmt. Basierend darauf ist der **Apriori**-Algorithmus [14] entwickelt worden, der effizienter Kandidaten generiert und als Standardalgorithmus in diesem Bereich gilt [143]. Der Apriori-Algorithmus nutzt **Pruning**-Techniken⁵, um uninteressante Itemsets von vornherein bei einzelnen Berechnungsschritten auszuschließen. So werden Rechenkapazität und Laufzeit gespart, während gleichzeitig die Vollständigkeit der Ergebnisse gewährleistet wird. Auf Grundlage des Apriori-Algorithmus sind viele weitere Algorithmen mit einigen Änderungen entwickelt worden um verschiedene Problemstellungen zu adressieren. Eine Übersicht über verschiedene Algorithmen ist in [116, 143, 149] zu finden. In Abschnitt 4.5.3 werden speziell für die Problemstellung dieser Arbeit geeignete Algorithmen näher vorgestellt.

⁵ ‚Pruning‘ kann mit dem deutschen Begriff „Zurechtstutzen“ übersetzt werden und bezeichnet ursprünglich Methoden zur Reduktion der Größe und Komplexität von Entscheidungsbäumen.

Association Rule Mining ist ein etabliertes unüberwachtes Lernverfahren (engl. *unsupervised learning*) zur explorativen Datenanalyse [19]. Neben Warenkorbanalysen findet es auch in weiteren Kontexten Anwendung, darunter Klassifikation, *Cross-Marketing*, *Clustering*, *Catalog Design* und *Loss-Leader Analyse* [149]. Für diese Arbeit ist vor allem der Einsatz von Association Rule Mining zur Klassifikation von Bedeutung. Dafür wird eine **Klassifikationsregel** der Form $X \Rightarrow C$ aufgestellt, wobei X einer Menge von Items und C einem Klassenlabel entspricht [53]. Mit einer solchen Regel kann eine Transaktion T einer Klasse C zugeordnet werden, sofern T die Items X enthält. So können beispielsweise wie in [65] im medizinischen Bereich Diagnosen gestellt werden. Dort werden mithilfe von Klassifikationsregeln Mammographie-Bilder gutartigen oder bösartigen Läsionen zugeordnet. Die Bilder enthalten dabei Merkmale, die mit der linken Seite der Klassifikationsregel X abgeglichen werden. Gleichzeitig dient X auch als Erklärung dafür, welche Merkmale mit welcher Ausprägung für die Zuordnung zu einem gutartigen oder bösartigen Läsion entscheidend sind. Dies ermöglicht eine detaillierte Analyse der Beziehung zwischen Items und einer Klasse, was in dieser Arbeit auf die Bestimmung des Zusammenhangs von Bildmerkmalen und Prozesserfolg übertragen wird.

4.5.2.2 REGELBEWERTUNG UND METRIKEN

Association Rule Mining-Algorithmen erzeugen typischerweise im Verlauf der Regelgenerierung einen umfangreichen Satz von Kandidaten und infolge dessen ebenso zahlreiche Regelkonstruktionen. Um nur interessante Assoziationsregeln zu finden, die starke Beziehungen zwischen Items offenlegen, werden sog. **Constraints**⁶ festgelegt, die als Schranken zu verstehen sind. Gefundene Regeln müssen dann die durch die Schranken festgelegten Schwellwerte überschreiten, um weiter betrachtet zu werden. Typische Constraints sind das Festlegen eines Minimums für folgende zwei Aspekte [108].

Der **Support** eines Itemsets X ist der Anteil der Transaktionen in D , die X enthalten:

$$\text{SUPPORT}(X) = \frac{|\{T \in D \mid X \subseteq T\}|}{|D|} \quad (4.3)$$

Basierend darauf beschreibt der **Support** einer Regel $X \Rightarrow Y$ den Anteil der Transaktionen in D , die alle Items aus X und Y enthalten:

$$\text{SUPPORT}(X \Rightarrow Y) = \text{SUPPORT}(X \cup Y) \quad (4.4)$$

⁶Der Begriff ‚Constraint‘ ist ein feststehender Begriff in der Wissenschaft und wird, genauso wie die verschiedenen Arten von Constraints, in der Arbeit mit seinem englischen Terminus verwendet.

Regeln mit hohem Support sind zuverlässiger und stabiler, da sie auf einer großen Menge an Daten basieren.

Die **Confidence** misst das Vertrauen in eine Regel bzw. ihre Zuverlässigkeit. Die Confidence einer Regel $X \Rightarrow Y$ betrachtet die Menge aller Transaktionen in D , die X enthalten und berechnet unter diesen, wie viele auch Y enthalten:

$$\text{CONFIDENCE}(X \Rightarrow Y) = \frac{\text{SUPPORT}(X \Rightarrow Y)}{\text{SUPPORT}(X)} \quad (4.5)$$

Wenn eine Regel einen hohen Support aufweist, aber gleichzeitig eine niedrige Confidence, so indiziert dies, dass die Regel zwar in vielen Fällen zutrifft, aber ihre Aussagekraft in Bezug auf die Vorhersage des zweiten Ereignisses (Y) vergleichsweise schwach ist. Zur Beurteilung von Regeln sollten also immer mehrere Metriken betrachtet werden.

Neben Support und Confidence existieren weitere Kenngrößen, mit denen generierte Assoziationsregeln bewertet oder weitere Constraints formuliert werden können. Für diese Arbeit weitere interessante Metriken werden im Folgenden erläutert [108, 156, 284].

Der **Lift** wird zur Bewertung der Stärke einer Regel berechnet durch

$$\text{LIFT}(X \Rightarrow Y) = \frac{\text{SUPPORT}(X \Rightarrow Y)}{\text{SUPPORT}(X) \times \text{SUPPORT}(Y)} \quad (4.6)$$

Der LIFT beschreibt den statistischen Zusammenhang für das gemeinsame Auftreten von X und Y . Dieser kann positiv ($\text{LIFT} > 1$), unabhängig ($\text{LIFT} = 1$) oder negativ ($\text{LIFT} < 1$) sein. Eine positive Abhängigkeit deutet auf eine interessante Regel, eine negative Abhängigkeit auf eine uninteressante Regel hin.

Die **Conviction** ist ebenfalls ein Maß zur Bewertung der Aussagekraft einer Regel:

$$\text{CONVICTION}(X \Rightarrow Y) = \frac{\text{SUPPORT}(X) \times (1 - \text{SUPPORT}(Y))}{\text{SUPPORT}(X) - \text{SUPPORT}(X \Rightarrow Y)} \quad (4.7)$$

Sind X und Y stochastisch unabhängig, gilt $\text{CONVICTION} = 1$. Sind X und Y dagegen perfekt positiv (negativ) korreliert, gilt $\text{CONVICTION} = \infty(0.5)$.

Der **Cosine** ist ein Maß zur Bewertung der Qualität einer Regel:

$$\text{COSINE}(X \Rightarrow Y) = \frac{\text{SUPPORT}(X \Rightarrow Y)}{\sqrt{\text{SUPPORT}(X) \times \text{SUPPORT}(Y)}} \quad (4.8)$$

Die Berechnungsvorschrift ist zu der des Lifts ähnlich, betrachtet aber die quadratische Wurzel des Produkts der Auftrittswahrscheinlichkeiten von X und Y . Dadurch wird das Ergebnis nur von den Support-Werten von X , Y , und $X \cup Y$ beeinflusst und nicht von der Anzahl aller Transaktionen in D . Der Cosine einer Regel kann Werte zwischen 0 und 1

annehmen, wobei höhere Werte auf stärkere Korrelationen von X und Y hinweisen.

Die **Imbalance Ratio** bewertet ungleiche Verteilungen in den Daten durch

$$\text{IRATIO}(X \Rightarrow Y) = \frac{|\text{SUPPORT}(X) - \text{SUPPORT}(Y)|}{\text{SUPPORT}(X) + \text{SUPPORT}(Y) - \text{SUPPORT}(X \Rightarrow Y)} \quad (4.9)$$

Dabei bedeutet ein Wert von $\text{IRATIO} = 0$, dass die direkten Implikationen von X und Y ($X \Rightarrow Y$ und $Y \Rightarrow X$) gleich sind. Interessant sind dagegen Regeln mit einem IRATIO -Wert nahe 1, da sie auf ein hohes Ungleichgewicht der betrachteten Itemsets in den Daten hinweisen. Seltene Fälle könnten in den generierten Regeln übersehen werden, sollten aber je nach Anwendungsfall ebenfalls berücksichtigt werden.

Die Metrik **Kulczynski** bestimmt ebenfalls die Korrelation von Itemsets durch das arithmetische Mittel der Confidence von X und Y :

$$\text{KULCZYNSKI}(X \Rightarrow Y) = \frac{1}{2}[\text{CONFIDENCE}(X \Rightarrow Y) + \text{CONFIDENCE}(Y \Rightarrow X)] \quad (4.10)$$

Das Kulczynski-Maß reicht von 0 bis 1. Je weiter der Wert des Kulczynski-Maßes von 0.5 entfernt ist, desto stärker korrelieren die betrachteten Itemsets X und Y .

Welche Metrik sich am besten für die Bewertung von Assoziationsregeln eignet, hängt von den betrachteten Daten, der Anwendung und dem gewählten Algorithmus ab [108]. Dieser Aspekt wird hinsichtlich der dieser Arbeit zugrunde liegenden Problemstellung in den nachfolgenden Experimenten untersucht.

4.5.3 UMSETZUNG MIT ASSOCIATION RULE MINING

Die Analyse relevanter Prozessdetails mit Hilfe von Association Rule Mining aus Bilddaten erfordert einige Teilschritte, die in Abbildung 28 illustriert sind. Die Teilschritte müssen nacheinander durchlaufen werden und beschreiben damit einen Prozess, der durch typische KDD-Prozesse inspiriert ist (Abschnitt 4.5.1). Die Eingabe ist entsprechend der Definition des Analyseschritts im Gesamtkonzept eine Menge gelabelter Bilddaten V . Ausgabe ist eine Regel, die relevante Prozessdetails enthält und hier als Abgrenzung zum Analyseansatz für unstrukturierte Daten als r_{sd} bezeichnet wird.

4.5.3.1 DATENVERARBEITUNG

Association Rule Mining-Algorithmen funktionieren nur auf strukturierten Daten. Wenn jedoch die Eingabedaten, wie in dieser Arbeit Bilder sind, handelt es sich um unstrukturierte Daten. Diese müssen zuerst in strukturierte Daten umgewandelt werden, um verarbeitet werden zu können. Eine typischerweise Vorgehensweise zur Strukturierung von



Abbildung 28: Teilschritte zur Umsetzung des Analyseschritts mit Association Rule Mining für strukturierte (Bild-)Daten.

Bilddaten erfolgt durch die Anwendung von Segmentierungsalgorithmen. Diese unterteilen das Bild in Regionen ähnlicher Merkmale, wodurch bestimmte Bildbereiche isoliert werden können. Genauso wie bei der Umsetzung mit LIME (Abschnitt 4.4.3) wird im Kontext dieser Arbeit für die Implementierung dieses Schritts die Pixelfarbe zur Segmentierung genutzt. Die verbleibenden Blobs werden auch bei diesem Ansatz anschließend hinsichtlich den gängigen Objektmerkmalen Form, Größe und Position analysiert. Auf diese Weise werden eine Reihe von Werten pro Merkmal gewonnen, die entsprechend gespeichert werden. Beispielsweise kann ein Bild mit den ausgewählten Merkmalen durch ein Quintupel (*Blau, Rund, Klein, (30, 50), 1*) beschrieben werden, was bedeutet, dass das Bild ein blaues, rundes, kleines Objekt an den Bildkoordinaten (30, 50) zeigt. Der letzte Eintrag in diesem Quintupel kennzeichnet das Label des Bilds. Der Wert 1 entspricht einem positiv gelabelten Bild, also ein Bild, das zu einer erfolgreichen Prozessausführung gehört. Das Ergebnis des Datenverarbeitungsschritts ist eine Tabelle T_S , die strukturierte Beschreibungen der Bilder mit der zugehörigen Label-Informationen enthält (vgl. Tabelle 4.4). Treten mehrere Objekte im Bild auf, die optisch nicht unterscheidbar sind, muss auch an dieser Stelle das Zuordnungsproblem (Abschnitt 4.4.3.2) gelöst werden. Auf diesen Aspekt wird im Rahmen des Ansatzes nicht weiter eingegangen, muss aber bei der Anwendung mit berücksichtigt werden.

#	Merkmale			Label
	Größe	Farbe	...	
Bild 1	Klein	Blau	...	1
...
Bild n	Groß	Rot	...	0

Tabelle 4.4: Beispiel für Tabelle T_S nach Strukturierung der Bilder.

#	Merkmale				Label
	Größe <i>Klein</i>	Größe <i>Groß</i>	Farbe <i>Blau</i>	...	
Bild 1	1	0	1	...	1
...
Bild n	0	1	0	...	0

Tabelle 4.5: Beispiel einer 1-aus-n-Kodierung T_H zu den Daten aus Tabelle 4.4.

4.5.3.2 REGELERZEUGUNG

In diesem Schritt werden Assoziationsregeln basierend auf den Eingabedaten durch Anwendung spezifischer Algorithmen abgeleitet. Algorithmen in diesem Bereich erfordern, dass die Eingabedaten **1-aus-n**-kodiert (engl. *one-hot-encoded*) sind. Diese Kodierung wird erreicht, indem eine Tabelle T_H erzeugt wird, die für jede auftretende Ausprägung eines kategorischen Merkmals in Tabelle T_S eine binäre Spalte enthält. Für jeden Datensatz in Tabelle T_H gibt der Wert ‚1‘ in einer Spalte an, dass das entsprechende Bild den zugehörigen Merkmalswert zeigt; andernfalls wird der Wert auf ‚0‘ gesetzt. 1-aus-n-Kodierung erhöht die Anzahl der Spalten einer Eingabetabelle um maximal $\sum_{e \in F_{NB}} (n_e - 1)$, wobei n_e der Anzahl der auftretenden Werte für alle nicht-binären Merkmale F_{NB} entspricht (vgl. Tabelle 4.5). Dieser Prozess kann zu relativ großen Tabellen führen, die sich negativ auf die Effizienz der Algorithmen und die Regelqualität auswirken können. Aus diesem Grund existieren verschiedene Varianten der **Diskretisierung** (engl. *discretization*), welche die Anzahl der Spalten reduzieren. Diskretisierung bezeichnet im Allgemeinen Methoden, um kontinuierliche Werte auf Kategorien abzubilden. Dies wird üblicherweise durch eine Unterteilung der kontinuierlichen Bereiche in Intervalle erreicht [144].

Die neu erstellte Datenstruktur T_H dient als Eingabe für einen ausgewählten Association Rule Mining-Algorithmus. Die Ausgabe ist eine Menge von Regeln R , die auf häufig auftretenden Itemsets im Datensatz basieren und vorgegeben Constraints einhalten. Darüber werden im Kontext dieser Arbeit nur Klassifikationsregeln betrachtet, d.h. Regeln, die ein Klassenlabel in ihrem Konsequent enthalten. Eine solche Regel zeigt dann den Einfluss von einem oder mehreren Merkmalen auf eine positive oder negative Prozessausführung. Regeln wie ‚(Größe = Klein) \Rightarrow (Farbe = Blau)‘ werden eliminiert, da sie nicht die Klassifikationsaufgabe unterstützen.

4.5.3.3 REGELSELEKTION

Wie zuvor erläutert und wie in den Ergebnissen im Abschnitt 4.5.5 erneut deutlich wird, generieren die meisten Association Rule Mining-algorithmen (abhängig von den definierten Constraints) mehr als eine Regel. Dies kann jedoch zu Problemen führen, da die Regeln genutzt werden sollen, um konkrete Handlungsweisungen für Prozessschritte abzuleiten. Die Verwendung von zwei oder mehr Regeln stellt eine Herausforderung für die gleichzeitige Berücksichtigung durch ProzessteilnehmerInnen dar und kann sogar zu unauflösbaren Widersprüchen führen. Beispielsweise können die Regeln ‚(Farbe = Lila) \Rightarrow (Label = 1)‘ und ‚(Form = Rechteckig) \Rightarrow (Label = 1)‘ unter der Annahme, dass alle verfügbaren lila Objekte kreisförmig sind, nicht gleichzeitig erfüllt werden. Daher muss aus der Menge generierter Regeln R genau eine, nämlich die **relevante Regel** $r_{sd} \in R$, ausgewählt

werden. Diese sollte die relevanten Prozessdetails enthalten und muss nach irgendeinem Kriterium als ‚beste‘ Regel im Vergleich zu den konkurrierenden Regeln identifiziert werden. Die Qualität einer Regel kann durch die Anwendung verschiedener Metriken M (z. B. Support, Lift) bestimmt werden. Eine einzelne Regel $r_m \in R$ wird als **beste Regel** hinsichtlich einer Metrik $m \in M$ definiert, wenn sie bzgl. m im Vergleich zu den anderen generierten Regeln den höchsten Wert erzielt, sodass gilt:

$$r_m = \arg \max_{r \in R} (m(r)) \quad (4.11)$$

Ist m die einzige betrachtete Metrik, ist r auch die relevante Regel r_{sd} . Werden mehrere Metriken in Betracht gezogen, wird die Regel ausgewählt, die über die meisten Metriken hinweg den höchsten Wert liefert. Die Berechnung der relevanten Regel lässt sich dann allgemein formulieren durch

$$r_{sd} = \arg \max_{r \in R} \left(\sum_{m \in M} \mathbb{I}[r = r_m] \right) \quad (4.12)$$

Hierbei steht $\mathbb{I}[\cdot]$ für die Indikatorfunktion, die den Wert 1 annimmt, wenn der Ausdruck innerhalb der Klammern wahr ist. Sonst nimmt sie den Wert 0 an. Als Beispiel dienen die Regeln ‚(Farbe = Gelb) \Rightarrow (Label = 1)‘ und ‚(Farbe = Blau) \Rightarrow (Label = 1)‘. Angenommen der Lift wird zur Bewertung der Regeln verwendet und die erste Regel weist einen höheren Wert als die zweite auf, dann gilt die erste Regel als beste und somit als relevante Regel. Sie enthält die Information, dass die Objektfarbe ‚Gelb‘ ein relevantes Prozessdetail ist. In dieser Arbeit werden für die Auswahl relevanter Regeln alle in Abschnitt 4.5.2.2 genannten Metriken betrachtet und implementiert. In den Experimenten wird geprüft, ob sich eine Metrik besonders für die Identifikation der relevanten Regel eignet.

4.5.4 EXPERIMENTE UND EVALUATION

Die Evaluation der entwickelten Methode erfolgt anhand der beiden Szenarien aus Abschnitt 4.3.2. Um den Fokus verstärkt auf die Anwendbarkeit des Ansatzes zu legen, wird der erste Schritt (Datenverarbeitung) vereinfacht, indem synthetisch strukturierte Daten generiert werden. Damit werden auch mögliche Probleme bei der Zuordnung der Objekte in den Bildern zu entsprechenden Spalten in der Tabelle vernachlässigt. Die Daten simulieren das Ergebnis nach einer Bildsegmentierung und -analyse basierend auf den ausgewählten Merkmalen und entsprechen der Darstellung in Tabelle 4.4. Die dadurch erhöhte Kontrolle über die Experimente wird genutzt, um den Einfluss verschiedener Faktoren gezielt zu untersuchen. Daher werden verschiedene Varianten für jedes Szenario erstellt.

Varianten zu Szenario 1:

- Variante 1.1 bildet eine Vergleichslinie für die anderen Varianten und umfasst 500 Datensätze, die Annahme eines makellosen Bildverarbeitungsschritts und eine gleiche Verteilung der positiven und negativen Labels (250 pro Klasse).
- Variante 1.2 simuliert Änderungen der Lichtverhältnisse und berücksichtigt Rauschen in den Objektgröße von bis zu 5 Pixeln.
- Variante 1.3 entspricht Variante 1.1, hat jedoch eine reduzierte Stichprobengröße auf 100 Datensätzen.
- Variante 1.4 entspricht Variante 1.1, berücksichtigt aber eine ungleiche Verteilung der Bilder, d.h. nur 1/3 der Datensätze sind positiv gelabelt.

Die relevante Regel r_{sd} in Szenario 1 hat die Form $‘(Farbe = Blau) \Rightarrow (Label = 1)’$ für alle Varianten.

Varianten zu Szenario 2:

- Variante 2.1 umfasst 500 rauschfreie Datensätze mit einer gleichen Verteilung der positiven und negativen Labels (250 pro Klasse).
- Variante 2.2 entspricht Variante 2.1, hat jedoch eine reduzierte Stichprobengröße auf 100 Datensätze.

Die beiden runden Objekte in Szenario 2 haben die Größen 50x50 und 60x60 (Größe des kleinsten rechteckigen Hüllkörpers (engl. *bounding box*) in Pixeln). Die Bildszene selbst trägt die Maße 507x672 Pixel, wodurch das obere Siebtel der Szene den Bereich mit den y-Werten $[576, 672]$ umfasst. Demnach gilt als erwartetes Ergebnis für dieses Szenario: $(Position_y = [576, 642]) \Rightarrow (Label = 1)$ bezogen auf das größere runde Objekt und $(Position_y = [576, 647]) \Rightarrow (Label = 1)$ bezogen auf das kleinere runde Objekt. Die gültigen Intervalle sind nach oben abhängig von der Größe der Objekte beschränkt, sodass die Objekte noch vollständig in der Szene sichtbar sind. Des Weiteren werden Objekte als im oberen Siebtel platziert betrachtet, wenn sich ihr Schwerpunkt noch innerhalb der Intervalle befindet.

Für die Experimente werden verschiedene Association Rule Mining-Algorithmen implementiert. Basierend auf den Anforderungen der Problemstellung und den Charakteristika der Eingabedaten ist es erforderlich, neben den Standardalgorithmen weitere Techniken zu betrachten. Um die Anwendbarkeit der entwickelten Methode angemessen zu beurteilen werden demnach den Anforderungen entsprechend passende Algorithmen berücksichtigt, was im nächsten Abschnitt genauer erläutert wird. In den Experimenten wird

evaluiert, ob einer der Algorithmen besonders effektiv relevante Prozessdetails aus den Daten extrahiert. Des Weiteren werden Validierungskriterien formuliert, um die Ergebnisse der Algorithmen in den verschiedenen Szenarien vergleichen zu können.

4.5.4.1 AUSGEWÄHLTE ALGORITHMEN

Die Auswahl der implementierten Algorithmen basiert auf Bedingungen, die mit der Problemstellung der Arbeit einhergehen. Lediglich Algorithmen, die für Klassifikationsprobleme geeignet sind, werden berücksichtigt. Außerdem treten aufgrund der in den Daten betrachteten Merkmale quantitative Attribute auf. Somit müssen die Algorithmen für große Datenbanken geeignet sein, die numerische Daten enthalten. Insgesamt werden vier Algorithmen implementiert, die diese Bedingungen erfüllen und von denen die wichtigsten Eigenschaften und Parameter⁷ im Folgenden zusammengefasst sind.

FP-G: Beim FP-Growth-Algorithmus (FP-G) nach [109] handelt es sich um einen Standardalgorithmus, der in vielen Anwendungen verwendet wird und somit eine gute Grundlage für Vergleiche bietet. Er ist eine Erweiterung und Optimierung des Apriori-Algorithmus und eignet sich daher besser zur Entdeckung versteckter Muster in großen Datenbanken. Der Algorithmus generiert häufige Itemsets gemäß einem vom Benutzer festlegbaren Minimums bzgl. des Supports min_{sup} .

Quant: Ein Algorithmus, der speziell für das Finden **quantitativer Assoziationsregeln** entwickelt worden ist, wird in [254] vorgestellt. Der Ansatz (Quant) ist vielversprechend für die Anwendungsfälle dieser Arbeit, da die Diskretisierung implizit erfolgt und somit die Intervallgrenzen der quantitativen Werte dynamisch ausgewählt werden. Intervalle numerischer Attribute werden fusioniert, bis eine vom Benutzer festgelegte Schwelle (max_{sup}) überschritten wird. Dieses Verfahren reduziert die Größe der Eingabetabelle, während wichtige Intervalle automatisch berechnet werden. Darüber hinaus kann die Generierung qualitativer Regeln durch einen Interessenscore R konfiguriert werden.

HyCli: Im Kontext der Arbeit von [286] ist ein Algorithmus (HyCli) zum Finden sog. **Hyperclique Patterns** entwickelt worden. Im Gegensatz zu den anderen betrachteten Algorithmen, die in ihren Verfahren implizit eine Pruningstrategie verwenden, die auf dem Support-Wert basieren, wird in diesem Ansatz ein objektives Maß (h-confidence) definiert, um starke **Affinitätsmuster** zu identifizieren. Daher ist es möglich, Muster in Datenbanken auch bei sehr niedrigen Support-Schwellwerten zu finden.

⁷Die Parameter der Algorithmen sind in der Implementierung ausführlich kommentiert: https://github.com/MyFi-UBT/thesis_implementation, zuletzt besucht: 01.03.2024.

GAR+: Weiter wird der **evolutionäre** Algorithmus GAR-plus (GAR+) aus [23] implementiert. Der Ansatz befasst sich mit der Aufgabe, quantitative Regeln aus großen Datenbanken zu entdecken. Eine vorherige Diskretisierung des Bereichs numerischer Attribute ist nicht erforderlich, da die Intervalle innerhalb des Algorithmus bestimmt werden. Wichtige Hyperparameter sind die Anzahl der generierten Regeln n_r , Generationen n_{gens} , Individuen in jeder Population p_{size} und Individuen, die an die nächste Generation weitergegeben werden s_{perc} . Weiterhin gibt es Gewichtungsfaktoren für Support w_s , Confidence w_c , Anzahl der Attribute w_{na} , Amplitude w_a und Re-Coverage w_r . Schließlich die Rekombinations- r_{prob} , Mutations- m_{prob} und die Auswahlwahrscheinlichkeit von Attributen für die Anfangspopulation a_{prob} . Ein Ausgangspunkt für die Generierung der Anfangspopulation muss durch den Hyperparameter *seed* festgelegt werden.

Der Diskretisierungsschritt ist bereits in einigen Algorithmen enthalten (Quant und GAR+). Für die anderen Algorithmen wird für diese Arbeit eine grundlegende Diskretisierung implementiert, die den Bereich auftretender Werte für quantitative Merkmale in gleich große Intervalle schneidet. Die Anzahl der Intervalle wird dabei durch den Hyperparameter *intervals* bestimmt. Auch im Kontext von Hycli wird die Anzahl der Intervalle durch diesen Wert festgelegt. Die Größen der Intervalle werden jedoch innerhalb des Verfahrens bestimmt und müssen nicht gleichmäßig sein.

Die generierten Regeln jedes Algorithmus unterliegen einer Unterschranke bzgl. des Confidence-Werts, die durch den Hyperparameter min_{conf} festgelegt ist. Darüber hinaus wird der Pruning-Ansatz von [33] implementiert, um die Anzahl der generierten Regeln noch weiter zu reduzieren. Der Ansatz eliminiert unnötig komplexe Regeln, indem er eine Mindestverbesserungsbedingung durch einen Schwellwert *minimp* definiert. Beide Varianten, d.h. ohne und mit Pruning, werden für jeden Algorithmus und jedes Szenario berechnet und im Vergleich evaluiert.

4.5.4.2 VALIDIERUNGSKRITERIEN UND OPTIMIERUNG

Zum Vergleich der Ergebnisse und zur Bewertung der Anwendbarkeit der Algorithmen im Kontext der Arbeit, werden verschiedene Validierungskriterien (VK) definiert.

Prozentsatz der Nichtentdeckungen (VK1): In jedem Algorithmus ist eine Parametrisierung erforderlich. Darunter weisen bestimmte Algorithmen (z.B. GAR+), eine signifikant höhere Anzahl an Konfigurationsmöglichkeiten auf als andere. Einige Hyperparametereinstellungen führen zu erfolgreichen Ergebnissen, d.h. die relevante Regel ist innerhalb der generierten Regeln enthalten. In anderen Hyperparametereinstellungen wird sie dagegen gar nicht entdeckt. Die korrekte Konfiguration des Algorithmus erweist sich

somit als entscheidend, wobei der Anteil erfolgreicher Hyperparametereinstellungen als Indikator für die Robustheit des Algorithmus betrachtet werden kann. Mithilfe dieses Validierungskriteriums wird berechnet, welcher Prozentsatz unterschiedlicher Hyperparametereinstellungen die relevante Regel nicht entdeckt. Ein niedriger Prozentsatz entspricht somit einer hohen Robustheit und steigert die Anwendbarkeit des Algorithmus. Darüber hinaus fungiert dieser Wert als Ausschlusskriterium. Erreicht ein Algorithmus bei diesem Kriterium 100% und findet damit die relevante Regel in keiner Hyperparametereinstellung, werden die übrigen Validierungskriterien nicht mehr berücksichtigt.

Anzahl der Regeln mit positivem Label (VK2): Für einen erfolgreichen Hyperparametersatz, d.h. für den die relevante Regel in der Menge der generierten Regeln enthalten ist, wird überprüft, wie viele andere Regeln das positive Klassenlabel (*Label = 1*) in ihrem Konsequent tragen. Diese stellen direkt konkurrierende Regeln dar, unter denen die relevante Regel ausgewählt wählen muss. Die Anzahl der Regeln mit einem positiven Klassenlabel bestimmen den Wert dieses Validierungskriteriums. Ein hoher Wert bedeutet eine hohe Anzahl direkt konkurrierender Regeln, was die Komplexität des Regelselektionsschritts erhöht. Fälle, in denen die Ergebnismenge der Algorithmen für einen erfolgreichen Hyperparametersatz genau eine Regel enthält, werden als optimal definiert. In diesen Situationen entspricht diese Regel exakt der relevanten Regel, was eine automatische Identifikation ermöglicht und somit die Selektion einer Regel obsolet macht.

Bestimmung der relevanten Regel als beste Regel (VK3): Das Kriterium betrifft den praktischen Einsatz des Ansatzes in zukünftigen Szenarien. Im Unterschied zu den Experimenten dieser Arbeit ist in realen Szenarien im Voraus nicht bekannt, welche der erzeugten Regeln relevant ist. Dort muss, wie im Schritt ‚Regelselektion‘ erläutert, die relevante Regel unter einer Menge von generierten Regeln selektiert werden. Die Zuverlässigkeit von typischen Bewertungsmetriken (Lift, Cosine, etc.) ist dabei entscheidend. Wenn die Anwendung einer oder mehrerer Metriken die relevante Regel als ihre beste Regel identifiziert, eignen sich diese Metriken im Allgemeinen für diesen Zweck. Wenn dies dagegen zu divergierenden Ergebnissen führt und die Metriken nicht zuverlässig die relevante Regel identifizieren, sind sie auch nicht für neue Szenarien geeignet. Das Validierungskriterium erhält den Wert j (*‚ja‘*), wenn eine Metrik existiert, welche die Identifikation der relevanten Regel unterstützt. Das bedeutet, dass die durch Gleichung 4.5.3.3 berechnete Regel der relevanten Regel entspricht. Damit erhält VK3 auch für die Fälle den Wert j , in denen nur eine einzige Regel generiert wird und diese der relevanten Regel entspricht. In allen anderen Fällen erhält das Kriterium den Wert n (*‚nein‘*).

Um VK1 (und folglich die anderen Kriterien) zu berechnen, ist es erforderlich, verschiedene Hyperparametersätze systematisch zu testen. Dabei wird Optuna [17] verwendet, um den Hyperparameterraum mithilfe einer Rastersuche zu erkunden. Optuna repräsentiert ein automatisches Framework zur **Hyperparameteroptimierung**, das gezielt für den Bereich des maschinellen Lernens konzipiert worden ist und effizient große Hyperparameterräume durchsuchen kann. Mithilfe von Optuna können optimale Hyperparametersätze gefunden und verschiedene Hyperparametersätze bewertet werden.

Für Szenario 1 wird jedem Hyperparametersatz p eines Algorithmus der Wert 0 zugewiesen, wenn die relevante Regel $(Farbe = Blau) \Rightarrow (Label = 1)$ nicht gefunden wird, d.h., nicht Teil der generierten Regelmenge des Algorithmus ist. Andererseits erhält p den Wert $1/|r_{L=1}|$. Der Wert $|r_{L=1}|$ entspricht dabei der Anzahl der generierten Regeln, die das positive Klassenlabel $(Label = 1)$ in ihrem Konsequent haben. Für Optuna wird durch diese Bewertungen ein Optimierungsproblem im Sinne eines Maximierungsproblem formuliert. Dabei wird der höchste Wert ($= 1$) folglich mit Hyperparametersätzen erreicht, die nur genau eine Regel mit einem positiven Klassenlabel erzeugen. Eine hohe Anzahl solcher konkurrierender Regeln resultiert in geringen Werten, die gegen 0 tendieren. Die Entscheidung für eine Optimierung hinsichtlich der Anzahl konkurrierender Regeln liegt im Regelselektionsschritt begründet. Der Erfolg des Ansatzes hängt in diesem Schritt von dem Finden einer zuverlässigen Metrik ab. Um die Abhängigkeit in dieser Dimension zu reduzieren, wird hinsichtlich der Algorithmen bzw. der damit verbundenen Hyperparameter optimiert. Allerdings können grundsätzlich, wie z.B. in [285] vorgestellt, auch andere Optimierungsziele gewinnbringend sein, die alternative Metriken einbeziehen.

Für Szenario 2 wird die Optimierungsfunktion leicht angepasst. Hyperparametersätze, bei denen Regeln gefunden werden, die y -Positionsbereiche $[y_{min}, y_{max}]$ zu den runden Objekten in ihrem Antezedenten enthalten und diese Bereiche sich innerhalb des idealen Intervalls $[t_{min}, t_{max}] = [576, 642]$ (bzw. $[576, 647]$) befinden, werden generell als erfolgreich betrachtet. Es gilt dann $y_{min} \geq t_{min}$ und $y_{max} \leq t_{max}$. Jedoch sind Regeln mit Intervallen, die näher den Idealbereich abbilden, besser zu bewerten. Zu diesem Zweck wird ein Distanzmaß d eingeführt, das die Abweichung des gefundenen Intervalls vom idealen Intervall angibt mit $d = 1 - ((y_{min} - t_{min}) + (t_{max} - y_{max})) / (t_{max} - t_{min})$. Dann hat d einen Wert zwischen 0 und 1, wobei 1 bedeutet, dass die in der Regel enthaltenen Intervallgrenzen genau denen des idealen Intervalls entsprechen. Die Qualität eines Hyperparametersatzes für das Finden der relevanten Regel wird dann durch $(1 + d) / |r_{L=1}|$ berechnet.

Hohe Werte kennzeichnen somit bessere Hyperparametersätze. Wenn mehrere Hyperparametersätze den maximalen Wert zurückgeben, wird ein zufälliger Satz aus ihnen für eine genauere Untersuchung bzgl. VK2 und VK3 ausgewählt.

4.5.5 ERGEBNISSE

Im nachfolgenden Abschnitt werden die Resultate der selektierten Algorithmen in Hinblick auf die zuvor definierten Validierungskriterien präsentiert. Die Szenarien werden nacheinander betrachtet, wobei die Darlegung der Ergebnisse im Form einer vergleichenden Analyse der Algorithmen für jedes Kriterium durchgeführt wird. Abschließend werden jeweils die Ergebnisse der einzelnen Szenariovarianten im Vergleich zur Basisvariante 1.1 diskutiert und darauf aufbauende Schlussfolgerungen für den Ansatz gezogen.

4.5.5.1 ERGEBNISSE ZU SZENARIO 1

Die Ergebnisse zu Szenario 1 sind in Tabelle 4.6 zusammengefasst.

Zu VK1: Alle Algorithmen finden die relevante Regel r_{sd} ohne Pruning über alle Varianten hinweg. Dabei sind FP-G und Quant besonders robust gegenüber Hyperparameteränderungen - sie erreichen minimale Werte von 0.0 und 0.2. Quant findet damit r_{sd} für alle betrachteten Hyperparametersätze in Varianten 1.1 - 1.3. GAR+ schneidet bei diesem Kriterium insgesamt am schlechtesten ab. In allen Varianten erzielt GAR+ ohne Pruning im Vergleich zu den anderen Algorithmen die größten Werte. Mit Pruning verschlechtern sich die Ergebnisse aller Algorithmen bzgl. VK1. Darunter bei den Algorithmen FP-G und GAR+ deutlich. Sie erreichen im Vergleich zu den anderen Algorithmen die schlechtesten Werte (zwischen 93.8% und 100%). Dort wird r_{sd} nur noch in wenigen Hyperparametersätzen oder nie gefunden.

Variante	VK1: Nicht entdeckt (%) (ohne/mit Pruning)				VK2: #Regeln mit L=1 (ohne/mit Pruning)				VK3: Beste Regel? (ohne/mit Pruning)			
	1.1	1.2	1.3	1.4	1.1	1.2	1.3	1.4	1.1	1.2	1.3	1.4
FP-G	0.2/ 99.8	0.2/ 99.6	0.2/ 100	34.0/ 97.3	8/ 1	2/ 1	8/ -	8/ 1	n/ j	n/ j	n/ -	n/ j
Quant	0.0/ 9.4	0.0/ 13.2	0.0/ 19.8	19.3/ 21.1	8/ 1	2/ 1	8/ 1	8/ 1	n/ j	n/ j	n/ j	n/ j
HyCli	16.6/ 17.6	16.6/ 17.3	16.8/ 18.0	33.0/ 33.8	1/ 1	1/ 1	1/ 1	1/ 1	j/ j	j/ j	j/ j	j/ j
GAR+	30.0/ 93.8	18.8/ 95.0	26.3/ 100	62.5/ 97.5	1/ 1	1/ 1	1/ -	1/ 1	j/ j	j/ j	j/ -	j/ j

Tabelle 4.6: Ergebnisse der Association Rule Mining Algorithmen bzgl. aller Validierungskriterien und Varianten zu Szenario 1 nach [82].

Zu VK2: FP-G und Quant erzeugen ohne Pruning für einen optimalen Hyperparametersatz immer konkurrierende Regeln (2 bzw. 8 Regeln). Pruning beeinträchtigt die Robustheit dieser Algorithmen (vgl. VK1) zwar negativ, verbessert jedoch die Ergebnisse bzgl. VK2. Unter Verwendung des Pruning-Ansatzes kann für einen optimalen Hyperparametersatz r_{sd} als einzige Regel gefunden werden. Ausnahme dabei bildet FP-G bei Variante 1.3, in der bereits bzgl. VK1 kein optimaler Hyperparametersatz gefunden werden konnte. Die Algorithmen HyCli und GAR+ identifizieren dagegen für einen optimalen Hyperparametersatz r_{sd} auch ohne Pruning immer als einzige Regel. Pruning bringt im Gegensatz zu den anderen beiden Algorithmen an dieser Stelle keinen Mehrwert.

Zu VK3: In allen Fällen, in denen das Ergebnis aus mehreren Regeln besteht (FP-G und Quant ohne Pruning), unterstützen die betrachteten Metriken nicht die Bestimmung von r_{sd} . Dabei scheitern die Metriken bereits an der Bestimmung einer besten Regel, weshalb folglich auch r_{sd} nicht identifiziert werden kann. Nur in den Fällen, in denen r_{sd} bereits als einzige Regel gefunden wird (vgl. VK2), erzielt VK3 positive Ergebnisse. Dieser Aspekt bestärkt die Eignung von Algorithmen wie HyCli oder GAR+.

Varianten im Vergleich: Die Ergebnisse werden durch Rauschen bzgl. eines Merkmals (Variante 1.2) nicht beeinflusst. In wenigen Fällen mit Pruning werden im Vergleich zu Variante 1.1 geringfügig schlechtere Werte erzielt (Quant und GAR+ in VK1). Dies deutet darauf hin, dass die ausgewählten Algorithmen auf Bildern angewendet werden können, ohne anspruchsvolle Vorverarbeitungsschritte aus dem Bereich Bildverarbeitung durchzuführen. Auch kleinere Datensätze (Variante 1.3) verschlechtern die Ergebnisse in den Fällen ohne Pruning nicht. Lediglich für HyCli ist eine geringfügige Verschlechterung von 16.6% auf 16.8% bzgl. VK1 zu verzeichnen. Allerdings können FP-G und GAR+ mit Pruning in dieser Variante r_{sd} mit keinem Hyperparametersatz finden. Darüber hinaus ist hervorzuheben, dass dies die einzige Variante ist, in der r_{sd} für die betrachteten Hyperparametersätze nie gefunden wird. Gerade für kleine Datensätze ist deshalb der gewählte Pruning-Ansatz aus diesem Grund kritisch zu betrachten und sollte angepasst werden. Insgesamt bestätigen die Ergebnisse zu Variante 1.3 dennoch die Annahme, dass Association Rule Mining grundsätzlich auch für kleine Datensätze geeignet ist und wertvolle Ergebnisse liefert. Ungleiche Verteilungen von positiv und negativ gelabelten Einträgen im Datensatz (Variante 1.4) haben den größten negativen Einfluss auf die Ergebnisse. Die Ergebnisse verschlechtern sich über alle Algorithmen im Vergleich zu Variante 1.1 durchschnittlich um 25.5% (bzgl. VK1 ohne Pruning). Dieser Aspekt sollte bei der Datensammlung zwingend berücksichtigt werden.

Zusammenfassend bestätigen die Ergebnisse die Effektivität der entwickelten Methode. Durch die Betrachtung relevanter Prozessdetails in Form von Beziehungen zwischen Datenmerkmalen (Objektmerkmale und Prozesserfolg) ergibt sich eine typische Problem-

stellung für Association Rule Mining Ansätze. Sie fokussieren sich auf das Aufdecken interessanter Beziehungen in Datensätzen und somit auch auf der Erklärung von Zusammenhängen in den Daten durch Regeln. Die Ergebnisse zeigen, dass diese Stärke erfolgreich genutzt werden kann, um unbekannte, aber relevante Prozessinformationen in Form einer relevanten Regel zu extrahieren. Dabei ist in Szenario 1 insgesamt keiner der implementierten Algorithmen für das Finden der relevanten Regel ungeeignet. Allerdings muss der verwendete Pruning-Ansatz für FP-G und GAR+ angepasst werden. HyCli zeigt sich insgesamt am effektivsten, da seine Robustheit gegenüber Hyperparameter-Änderungen überdurchschnittlich ist ($< 17\%$ ohne Pruning und $< 58\%$ mit Pruning). Außerdem findet HyCli in allen Varianten die relevante Regel als einzige Regel und ist somit nicht auf die Unterstützung von Metriken angewiesen. Abschließend ist zu der Anwendung von GAR+ in diesem Szenario noch anzufügen, dass die Ergebnisse basierend auf einem festgelegten Startwert ($seed = 17$) berechnet werden. Aufgrund der nicht-deterministischen Eigenschaft des Algorithmus ist es dagegen erforderlich, den Hyperparameterraum auch mit verschiedenen Startwerten zu explorieren. Zur Abschätzung wie stark der Startwert auf das Ergebnis Einfluss nimmt, wird ein optimaler Hyperparametersatz mit dem o.g. Startwert berechnet. Anschließend wird geprüft, ob dieser auch unter acht weiteren zufällig gewählten Startwerten als optimal betrachtet werden kann. Der gewählte Hyperparametersatz zeigte sich nur in drei der acht Fälle als optimal, wovon ein starker Einfluss des Startwerts auf die Ergebnisse abzuleiten ist. Trotz dieser Erkenntnisse wird der identifizierte Hyperparametersatz für nachfolgende Berechnungen (VK2 und VK3) mit GAR+ herangezogen. Ziel der Evaluation ist die Bestimmung einer Tendenz ob GAR+ für die vorliegende Problemstellung grundsätzlich geeignet ist. Es sei jedoch betont, dass weiterführende Studien unabdingbar sind, um eine umfassend verlässliche Beurteilung des Algorithmus zu gewährleisten.

4.5.5.2 ERGEBNISSE ZU SZENARIO 2

Tabelle 4.7 zeigt die Ergebnisse der Ausführung der Algorithmen zu Szenario 2.

Zu VK1: Mit den Algorithmen FP-G und HyCli kann die relevante Regel r_{sd} gefunden werden. Allerdings ist der Erfolg nur auf wenig Hyperparametersätze beschränkt. Dabei verschlechtert sich das Ergebnis für FP-G unter Einbezug des Pruningansatzes (um etwa 10%). Für HyCli sind minimale bis keine Unterschiede bei der Durchführung ohne und mit Pruning zu beobachten. Quant wird bei der Evaluation zu Szenario 2 ausgeschlossen, da kein Hyperparametersatz bestimmt werden kann, der Ergebnisse in angemessener Laufzeit (< 24 Stunden) liefert. Für diesen Algorithmus weisen die Datensätze eine zu hohe inhaltliche Komplexität auf. Dabei führt die Vorgehensweise des Algorithmus, die

Variante	VK1: Nicht entdeckt (%) (ohne/mit Pruning)		VK2: #Regeln mit L=1 (ohne/mit Pruning)		VK3: Beste Regel? (ohne/mit Pruning)	
	2.1	2.2	2.1	2.2	2.1	2.2
FP-G [109]	84.5/96.3	84.5/94.5	65536/1	196606/1	n / j	n / j
Quant [254]	- / -	- / -	- / -	- / -	- / -	- / -
HyCli [286]	95.0/95.0	92.5/92.6	1 / 1	1 / 1	j / j	j / j
GAR+ [23]	100/100	100/100	- / -	- / -	- / -	- / -

Tabelle 4.7: Ergebnisse der Association Rule Mining Algorithmen bzgl. aller Validierungskriterien und Varianten zu Szenario 2 nach [82].

Intervallgrenzen quantitativer Attribute dynamischen zu bestimmen, zu sehr hohem Rechenaufwand und Speicherbedarf für Szenario 2. Mit GAR+ können zwar Ergebnisse in akzeptabler Zeit berechnet werden, allerdings findet keiner der überprüften Hyperparametersätze r_{sd} , weder mit noch ohne Pruning.

Zu VK2: Für einen optimalen Hyperparametersatz generiert FP-G ohne Pruning eine große Anzahl an Regeln, die das Ergebnis stark verwässern (65536 in Variante 1.1 und 196606 in Variante 1.2). Allerdings kann durch die Verwendung des Pruning-Ansatzes r_{sd} als einzige Regel gefunden werden. Dieses Ergebnis verdeutlicht die essenzielle Bedeutung von Pruning-Ansätze bei der Verwendung von FP-G auf Daten, die in ihrer Komplexität mit denen aus Szenario 2 vergleichbar sind. HyCli findet für einen optimalen Hyperparametersatz mit und ohne Pruning r_{sd} als einzige Regel.

Zu VK3: Der Einsatz von Metriken zur Identifikation von r_{sd} ist für Szenario 2 nur im Fall von FP-G ohne Pruning sinnvoll. Allerdings liefert keine der untersuchten Metriken einen Wert, der r_{sd} von den anderen Regeln der Ergebnismenge abhebt.

Varianten im Vergleich: Ähnlich zu den Ergebnissen in Szenario 1 führt ein kleinerer Datensatz (Variante 2.2) im Vergleich zu Variante 2.1 nicht zu signifikant unterschiedlichen Ergebnissen. Lediglich bei der Anwendung von FP-G ohne Pruning werden fast 3-mal so viele Regeln erzeugt. Dieses Ergebnis zeigt, dass sich die Einsetzbarkeit von FP-G mit abnehmender Datensatzgröße verschlechtert. Hingegen ist anzunehmen, dass mit zunehmender Datensatzgröße aussagekräftige Ergebnisse erzielt werden können, was allerdings die Anwendung von FP-G im Fall von realen Daten uninteressant macht.

Zusammenfassend liefert HyCli auch in Szenario 2 die besten Ergebnisse. Trotz der durchschnittlich etwas geringeren Hyperparameterrobustheit gegenüber FP-G, sind die effektiven Ergebnisse zu VK2 entscheidend. Dies bestätigt die Anwendbarkeit der entwickelten Methoden zur Extraktion relevanter Prozessdetails auch für im Vergleich zu Szenario 1 komplexeren Anwendungsfällen. Dabei liegt eine zentrale Herausforderung der

Methode in der Bestimmung geeigneter Datenmerkmale für die Analyse. Dieser Aspekt ist entscheidend für den Erfolg des Ansatzes und erfordert Fachwissen von ProzessexpertInnen in der entsprechenden Domäne. Im nächsten Abschnitt wird diese Vorbedingung sowie weitere Punkte im Rahmen eines Vergleichs mit der Methode für unstrukturierte Daten diskutiert. In Abschnitt 6.1 wird dieses Thema außerdem im Kontext der Anwendung des Gesamtkonzepts in verschiedenen Domänen noch einmal aufgegriffen.

4.6 VERGLEICH DER ENTWICKELTEN ANSÄTZE UND DISKUSSION

Die entwickelte Methoden basierend auf LIME und Association Rule Mining bringen verschiedene Anforderungen sowie Vor- und Nachteile mit sich. Gerade bei der Anwendung in realen Prozessumgebungen müssen neben ihrer Eignung für verschiedene Datenstrukturen vor allem folgende Aspekte berücksichtigt werden.

Prozess- und Domänenwissen: Der Ansatz mit LIME beschreibt bis zum Globalisierungsschritt ein lokales post-hoc Verfahren. Somit kann das Verhalten des mit den Bild-daten angelernten CNNs ohne tiefere Kenntnisse über die Szenarien und Daten erklärt werden. Erst bei Anwendung des Globalisierungsschritt ist Prozess- und Domänenwissen, z.B. zu Objekten in der Szene, zwingend erforderlich, um aussagekräftige Ergebnisse zu erzeugen. Diese Eigenschaft bietet mehr Flexibilität im Vergleich zum Vorgehen mittels Association Rule Mining. Zur Verarbeitung unstrukturierter Daten muss dort eine vorherige Strukturierung erfolgen, für welche die Einbindung von Kontextwissen zwingend erforderlich ist und stark die Effektivität des Ansatzes beeinflusst. Werden uninteressante Merkmale der Daten ausgewählt oder nicht korrekt abgebildet, können Association Rule Mining Algorithmen keine relevanten Regeln finden. Die Anwendung des vorderen Teils des LIME-Ansatzes ist dagegen weitgehend unabhängig vom Einsatzgebiet. Dennoch können die Ergebnisse unter Verwendung von Prozesswissen optimiert werden, was am Ende dieses Abschnitts diskutiert wird.

Datencharakteristika: Im Rahmen dieser Arbeit werden vereinzelt weiterführende Experimente zum Ansatz mit LIME durchgeführt, um den Einfluss der Datenmenge auf das Ergebnis zu evaluieren. Darunter zeigte sich, dass für Szenario 1 beim Ansatz mit LIME auch kleinere Datenmengen ausreichen als in den in Abschnitt 4.4.4 durchgeführten Experimenten. Für Szenario 1 ist, genauso wie beim Ansatz mit Association Rule Mining, ein Datenbestand von 100 Bildern ausreichend, um die gesuchten relevanten Prozessdetails zu identifizieren. Für Szenario 2 führte dagegen eine Reduktion auf diese Datenmenge zu

einer deutlichen Verschlechterung der Ergebnisse. Der Ansatz mit Association Rule Mining erfordert damit einen geringeren Datenbestand für die Extraktion relevanter Details. In Szenario 2 benötigt er lediglich 10% der Datenmenge im Vergleich zum LIME-Ansatz, um erfolgreiche Ergebnisse zu liefern.

Weiter wird aus den Ergebnissen zum Ansatz mit Association Rule Mining ersichtlich, dass eine gleichmäßige Verteilung positiv und negativ gelabelter Datensätze notwendig ist, um die Effektivität des Ansatzes zu gewährleisten. In Abschnitt 6.4.3 wird außerdem ersichtlich, dass für den Ansatz mit LIME in komplexeren Szenarien Anforderungen an die Datenvariabilität gelten. Reale Prozessumgebungen, insbesondere kleine und mittelständische Unternehmen, können Schwierigkeiten bei der Bewältigung sowohl der hohen Variabilität in den Daten als auch der Bereitstellung ausreichend großer Mengen haben.

Daher sind alternative Strategien in realen Umgebungen erforderlich. Ansätze zur (synthetischen) Vergrößerung von Datensätzen (engl. *data augmentation*) könnten diesem Problem entgegenwirken. Aus kleinen Datensätzen können so eine ausreichende Menge an Daten generiert werden. Darüber hinaus könnten im Kontext des LIME-Ansatzes bereits trainierte CNNs aus ähnlichen Domänen mit vergleichbaren Prozessen und Objekten genutzt werden, um die Anwendung in der Praxis effektiv zu unterstützen.

Hyperparametrisierung: Die Qualität der Ergebnisse beider Methoden ist von einer korrekten Konfiguration und damit verbunden der Wahl geeigneter Hyperparameter abhängig. Die Identifikation optimaler Hyperparameter gestaltet sich als anspruchsvoll, insbesondere im Kontext neuer Szenarien. Beim Ansatz mit Association Rule Mining ist deshalb für reale Prozessumgebungen auf die hohe Hyperparameterrobustheit eines Algorithmus besonderen Wert zu legen. Im Gegensatz zu diesem Ansatz können bei LIME unter Einbezug von Prozesswissen passende Hyperparameter gewählt werden, um die Ergebnisse zu optimieren. Kenntnisse über die Anzahl und Form von Objekten, die in einer Aufgabe verwendet werden, steigern den Erfolg der Methode (Abschnitt 6.4.3.2).

4.7 ZUSAMMENFASSUNG

In diesem Kapitel wird demonstriert, wie datenorientierte relevante Prozessdetails aus Bilddaten extrahiert werden können, die während Prozessausführungen erfasst worden sind. Für die konkrete Umsetzung werden prototypisch zwei Techniken implementiert, die unterschiedliche Struktureigenschaften der Daten berücksichtigen. Zum einen wird LIME verwendet, um in unstrukturierten Bilddaten relevante Regionen zu identifizieren. Zum anderen werden Segmentierungstechniken genutzt, um Bilddaten zu strukturieren und mit Association Rule Mining Algorithmen interessante Beziehungen innerhalb der

Dateneinträge zu finden. Auf Basis dieser Techniken werden Methoden entwickelt, die als Ergebnis eine Regel liefern, welche relevante Prozessinformation enthält. Die Methoden werden anhand von zwei verschiedenen Szenarien evaluiert, die einen Platzierungsschritt im Metallspritzgussprozess illustrieren.

Die Ergebnisse bestätigen die Anwendbarkeit beider entwickelten Ansätze zur Extraktion relevanter Prozessdetails und untermauern damit die Umsetzbarkeit und Konzeption des Analyseschritts. Durch die Experimente wird deutlich, dass die Wahl passender Hyperparameter essenziell ist, um die Effektivität der Ansätze zu gewährleisten. Außerdem erfordert ihre erfolgreiche Anwendung die Bereitstellung einer ausreichenden Datenquantität und -qualität. Beide Aspekte müssen im Kontext neuer Szenarien und ihrer Komplexität entsprechend berücksichtigt werden. Aus diesen Beobachtungen werden wichtige Erkenntnisse für künftige Forschungsarbeiten gewonnen, insbesondere in Hinblick auf Optimierungen bzgl. der Robustheit. Diese Thematik wird in späteren Teilen der Arbeit erneut aufgegriffen (Abschnitte 6.4.3.2 und 8.3).

Die Ergebnisse bekräftigen Bilddaten als äußerst wertvolle Quelle für die Analyse relevanter Prozessdetails. Ihr hoher Informationsgehalt unterstützt die Entdeckung der gesuchten Information in den Experimenten und ermöglicht außerdem die Identifikation weiterer Typen relevanter Prozessdetails. Den beschriebenen Vorgehensweisen zur Umsetzung der Methoden folgend eignen sie sich außerdem zur Analyse organisatorischer und operationaler relevanter Prozessdetails durch Betrachtung anderer Merkmale im Bild (Personen, Werkzeuge). Dabei ist bei der Anwendung der Methoden grundsätzlich zu berücksichtigen, dass die Selektion geeigneter Merkmale eine Voraussetzung für eine effektive Analyse relevanter Prozessinformation sind. Dieser Aspekt sollte unter Einbezug von Prozess- und Domänenwissen erfolgen. Werden Datenquellen betrachtet, die direkt strukturierte Daten liefern (z.B. Temperatursensoren) sind die zu betrachtenden Merkmale bereits vorgegeben. In solchen Fällen kann der Ansatz mit Association Rule Mining wie in Abschnitt 4.5.3 beschrieben ohne den einleitenden Strukturierungsschritt angewendet werden. Fachwissen ist dann eher im Kontext der Selektion einer geeigneten Datenquelle gefordert, was in Abschnitt 6.1 genauer erläutert wird.

Insgesamt deckt die Demonstration der Methoden anhand spezifischer Szenarien aus der Fertigungsindustrie auf, an welchen Stellen tiefergreifendes Prozesswissen erforderlich ist, um den gewünschten Erfolg zu erzielen. Dabei wird deutlich, dass unter Berücksichtigung dieses Aspekts eine Anpassung des Analyseschritts und damit des Gesamtkonzepts an verschiedene Anwendungsfälle möglich ist. Zur Verdeutlichung dieser Eigenschaft werden in Kapitel 6 weitere Experimente am Beispiel einer alternativen Domäne durchgeführt und die damit verbundene Anwendbarkeit des Konzepts im Kontext verschiedener Prozesse diskutiert.

5 | ERSTELLUNG DER AUFGABENANNOTATIONEN

Dieses Kapitel beschäftigt sich mit dem Annotationsschritt der Verbesserungsphase des Gesamtkonzepts (vgl. Abbildung 3.3). Der Schritt besteht aus zwei Teilschritten und befasst sich mit Forschungsfrage 2 aus Abschnitt 1.3, d.h. wie relevante Prozessdetails in Prozessmodelle integriert werden können. Darunter befassen sich die kommenden Abschnitte insbesondere mit dem ersten Teilschritt, der Erzeugung von Aufgabenannotationen. Aufgabenannotationen dienen als Elemente, welche die Beschreibung einer Aufgabe in einem Prozessmodell erweitern bzw. konkretisieren. Dabei liegt der Fokus darauf zu untersuchen, welche Repräsentationsformate grundsätzlich existieren und ob sich verschiedene Formate abhängig von der Aufgabenstellung besser oder weniger gut eignen. Zur Adressierung dieser Problemstellung bietet das Kapitel zunächst einen Überblick über verschiedene Studien im Kontext Prozessmodellierung und Verständlichkeit (Abschnitt 5.1). Aufgrund der noch offenen Forschungslücke zu der betrachteten Thematik wird eine eigene experimentelle Nutzerstudie entwickelt und durchgeführt, um die Intuitivität von Aufgabenannotationen zu untersuchen (Abschnitt 5.2). Die Ergebnisse der Studie unterstützen ModelliererInnen bei der Wahl eines geeigneten Repräsentationsformats für Aufgabenannotationen (Abschnitt 5.3). Damit geben sie insbesondere Aufschluss über die zweite Teilfrage von Forschungsfrage 2, wie relevante Prozessdetails intuitiv verständlich in Prozessmodellen dargestellt werden können. Abschließend werden die erste und dritte Teilfrage adressiert, d.h. wie analysierte relevante Prozessdetails nachverarbeitet werden müssen, um verwendet werden zu können und wie bereits existierende Prozessmodelle um Details ergänzt werden können. Dies erfolgt durch die Beschreibung der Umwandlung relevanter Details in Aufgabenannotationen sowie der Vorstellung technischer Möglichkeiten, sie in Prozessmodelle zu integrieren (Abschnitt 5.4).

Der Studienaufbau und ein Großteil der Ergebnisse sind bereits in [80] veröffentlicht. Im Rahmen der zugehörigen Abschnitte 5.2 und 5.3 werden zusätzliche Inhalte und Auswertungen präsentiert und die Ergebnisse in vertiefter Form diskutiert.

5.1 BISHERIGE STUDIEN ZUR VERSTÄNDLICHKEIT VON PROZESSMODELLEN

Wie in Abschnitt 1.2.1 erörtert, ist eine der Herausforderungen bei der Prozessmodellierung, einen Prozess verständlich in einem Prozessmodell abzubilden (Anforderung 2). Der Erfolg eines Prozesses kann nur dann gewährleistet werden, wenn das Prozessmodell von allen beteiligten AkteurInnen korrekt interpretiert wird. Dabei muss eine Modellierungssprache sowohl die Erstellung von Modellen als auch ihr Verständnis bzw. ihre Interpretation unterstützen [97]. Im Allgemeinen wird das Thema Verständlichkeit im Modellierungskontext aus verschiedenen Perspektiven diskutiert, die sich in drei Kategorien unterteilen lassen [80]:

1. **Vergleich von Prozessmodellierungssprachen** hinsichtlich ihrer Verständlichkeit,
2. Untersuchung des Einflusses einzelner **Modellierungselemente** auf die Verständlichkeit von abgebildeten Prozessen und
3. Bewertung unterschiedlicher **Repräsentationsformate** von Prozessen in Bezug auf ihre Verständlichkeit.

Wesentliche Beiträge zu diesen Kategorien werden im Folgenden erläutert.

Vergleich von Prozessmodellierungssprachen: In dieser Kategorie existiert eine Vielzahl von Studien und Forschungsansätzen [76, 89, 131, 198, 279]. Beispielsweise werden in [279] vier unterschiedliche Prozesse in verschiedenen Modellierungssprachen (UML, BPMN, EPC und *Subject Behaviour Diagrams* (SBD)) modelliert. Anschließend beantworten die StudienteilnehmerInnen sechs Verständnisfragen (Einfach- und Mehrauswahl) zu den Kontrollflusselementen. Die Beurteilung der Verständlichkeit leitet sich aus den pro Notation erzielten Punktzahlen ab. Die Studienergebnisse zeigen, dass BPMN und UML im Vergleich zu EPC und SBD verständlicher sind. In [131] wird ebenfalls die Bedeutung der verschiedenen Prozessdarstellungen durch eine Reihe von Verständnisfragen bewertet. Auch dort wird BPMN und UML verständlicher als EPC befunden, vor allem für komplexere Prozesse.

Modellierungselemente: Die Elemente von Prozessmodellierungssprachen ermöglichen die Beschreibung verschiedener Aspekte eines Prozesses, z.B. den Kontrollfluss oder beteiligte Rollen. Dabei können einzelne Elemente einen starken Einfluss auf die Verständlichkeit eines Modells haben. In [35] werden die Auswirkungen von sog. *Swimlanes* in BPMN-Modellen auf das Verständnis untersucht. *Swimlanes* ermöglichen die grafische

Aufteilung eines BPMN-Diagramms in Abschnitte, wobei jeder Abschnitt eine bestimmte Rolle, Abteilung oder sogar eine externe Entität repräsentiert, die an einem Prozess beteiligt ist [186]. Durch zwei empirische Studien identifiziert die Arbeit das Konstrukt von *Swimlanes* in BPMN als Ursache für kognitive Überlastung. Dagegen untersucht beispielsweise die Studie von [169] den Zusammenhang zwischen den Kanten von Prozessmodellen und ihrer Verständlichkeit. Die Ergebnisse zeigen, dass die Anzahl der Kanten einen wichtigen Einfluss auf das Gesamtverständnis eines Modells hat.

Repräsentationsformate: Arbeiten aus dieser Kategorie untersuchen den Einfluss unterschiedlicher Möglichkeiten zur Darstellung von Prozessen auf ihre Verständlichkeit. Hinsichtlich dieses Aspekts vergleicht [228] rein textbasierte Darstellungsformen mit diagrammbasierten Darstellungen von Prozessen. Die Ergebnisse zeigen, dass die Verwendung von textuellen Arbeitsanweisungen die Verständlichkeit von Prozessen für Laien und ExpertInnen nicht negativ beeinflusst. Allerdings sind grafische Notationen für erfahrene BenutzerInnen lesbarer. Die Verständlichkeit jedes Darstellungstyps wird anhand von zehn Verständnisfragen bewertet. Darüber hinaus untersucht [90] verschiedene Darstellungsformate von Aufgaben. Es wird evaluiert, ob die inhaltliche Aufgabenstellung einen Einfluss darauf hat, welches Repräsentationsformat von Prozessbeteiligten bevorzugt wird. Dafür berücksichtigen die AutorInnen drei Arten von Formaten: textuell, strukturierter Text und diagrammatisch. Jedes Format wird in einer Studie mit und ohne Symbole evaluiert. Das Vorwissen im Bereich der Prozessmodellierung wird in Bezug auf Modellierungserfahrung und Modellierungsvertrautheit bewertet. Die Modellierungserfahrung beschreibt, wie viele Prozessmodelle die Teilnehmenden zuvor gelesen oder erstellt haben. Die Modellierungsvertrautheit wird mit Hilfe sechs verschiedener Arten von konzeptionellen Modellen bestimmt. Dafür werden die TeilnehmerInnen gebeten, die Prozessmodelle den zugrundeliegenden Modellierungssprachen zuzuordnen, wobei ihre Antworten entsprechend beurteilt werden. Um die Repräsentationsformate zu vergleichen, werden die ProbandInnen angewiesen, vier Aufgabenstellungen hinsichtlich ihrer bevorzugten Repräsentationsformate durch paarweise Vergleiche zu bewerten. Die AutorInnen kommen zu dem Schluss, dass Diagramme für alle Aufgaben am besten beurteilt werden und strukturierter Text durchgehend gegenüber reinem Text bevorzugt wird.

5.2 EXPERIMENTELLE STUDIE ZUR BEWERTUNG VON AUFGABENANNOTATIONEN

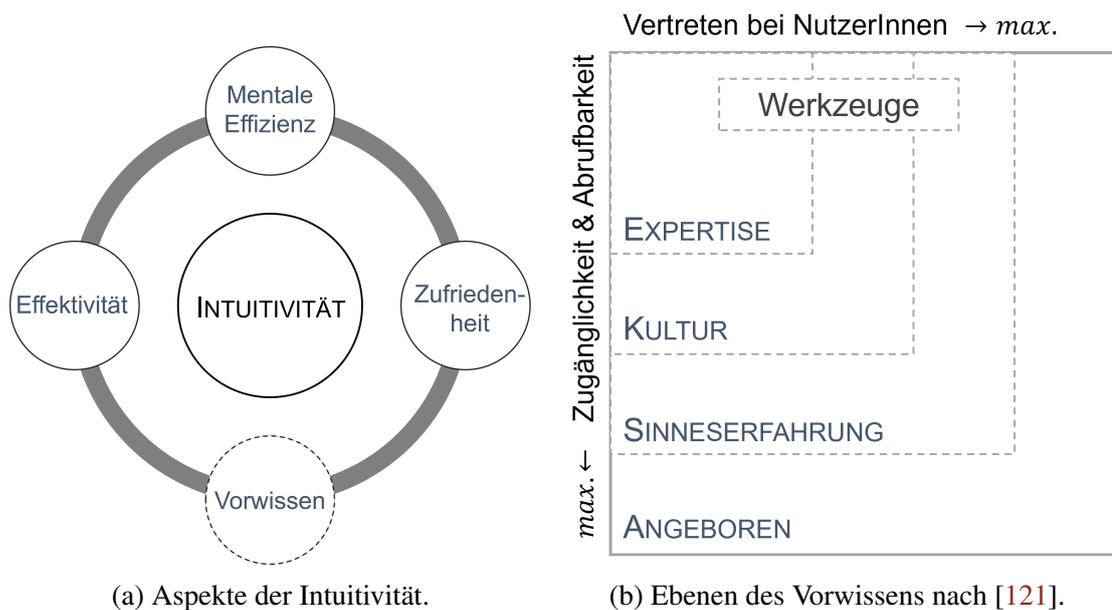
Die Ergebnisse bisheriger Studien liefern Hinweise darauf, welche Aspekte zugunsten der Verständlichkeit von Prozessmodellen berücksichtigt werden müssen. Außerdem geben sie insgesamt einen guten Anhaltspunkt für die Wahl einer passenden Prozessmodellierungssprache abhängig vom Prozesskontext. Sie bieten allerdings keine Unterstützung hinsichtlich der Darstellung von Prozessdetails in einem Modell, da es zu diesem Gesichtspunkt noch keine Untersuchungen gibt. Aus diesem Grund wird ein eigenes Studienkonzept entwickelt, das gezielt diese Fragestellung adressiert. Das Studiendesign baut auf vorheriger Forschung auf und ergänzt den Bestand an bisherigen Messinstrumenten zur Untersuchung der Verständlichkeit von Prozessmodellen nachhaltig.

5.2.1 VERSTÄNDLICHKEIT UND INTUITIVITÄT

Die Lesbarkeit bzw. Verständlichkeit eines Prozessmodells steht in direktem Zusammenhang mit seiner **Gebrauchstauglichkeit** (engl. *usability*) [118]. Dabei gilt als ein wesentliches Kriterium für die Gebrauchstauglichkeit einer Prozessmodellierungssprache, dass sie die Übersetzung zwischen kognitiven und visuellen Modellen unterstützt [89]. Allgemein wird Gebrauchstauglichkeit als Leichtigkeit bei der Interaktion mit einem System verstanden [173, 181]. Die ISO-Norm 9241-11 bestimmt die Bewertung der Gebrauchstauglichkeit eines Systems durch die Messung der drei Aspekte **Effektivität** (engl. *effectiveness*), **Effizienz** (engl. *efficiency*) und **Zufriedenheit** (engl. *satisfaction*) [244]. Die Effektivität ergibt sich aus der Fähigkeit von BenutzerInnen, mit einem System Aufgaben abzuschließen. Die Effizienz beschreibt die für die Bearbeitung der Aufgaben benötigten Ressourcen. Die Zufriedenheit wird durch das Feedback der BenutzerInnen abgebildet.

Die Gebrauchstauglichkeit eines Systems muss immer in dem Kontext betrachtet werden, in dem es angewendet wird [46]. Dies schließt auch die Definition der infrage kommenden BenutzerInnengruppe und des Anwendungsbereichs des Systems ein. Viele Systeme zielen darauf ab, von unerfahrenen BenutzerInnen verwendet werden zu können, die über keine oder wenige Vorkenntnisse im Umgang damit verfügen. Die Gebrauchstauglichkeit eines Systems muss daher intuitiv und selbsterklärend sein. Aus dieser Anforderung hat sich die **intuitive Benutzbarkeit** bzw. **Intuitivität**¹ als Unterkonzept der Gebrauchstauglichkeit entwickelt. Im Gegensatz zur Definition der Gebrauchstauglichkeit konzentriert sich die intuitive Benutzbarkeit auf eine geringe mentale Anstrengung und

¹Die Begriffe ‚intuitive Benutzbarkeit‘ und ‚Intuitivität‘ werden in dieser Arbeit synonym verwendet.



(a) Aspekte der Intuitivität.

(b) Ebenen des Vorwissens nach [121].

Abbildung 29: Intuitivität als Unterkonzept der Gebrauchstauglichkeit (links) und verwendete Ebenen des Vorwissens bei intuitiver Benutzung (rechts).

die unbewusste Anwendung von Vorwissen [174, 278]. Sie wird durch die drei Kenngrößen **Effektivität**, **mentale Effizienz** und **Zufriedenheit** gemessen und muss unter Einbeziehung des Vorwissens von NutzerInnen evaluiert werden (vgl. Abbildung 29a).

Dabei existieren verschiedene Ebenen des Vorwissens, die in Abbildung 29b zusammengefasst sind [121]. Die unterste Ebene beschreibt eine Form von angeborenem Wissen im Sinne von Reflexen und Instinkten. Die Ebene der Sinneserfahrung wird zum größten Teil in der frühen Kindheit erworben und umfasst Kenntnisse über die Welt, z.B. die Existenz von Gravitation. Die anschließende Ebene beschreibt Wissen, das durch die Zugehörigkeit zu einer bestimmten Kultur erworben wird. Die oberste Ebene umfasst spezielles Wissen bzw. eine Expertise in einem bestimmten Bereich. Insgesamt gilt, je höher der Grad des Wissens in einer der Ebenen, desto weniger Personen besitzen dieses Wissen. Dementsprechend ist spezielleres Wissen in der Gesellschaft weniger zugänglich und abzurufen als angeborenes Wissen, da es komplexere Prozesse umfasst und schwieriger zu erlernen ist. Das Beherrschen von Werkzeugen stellt auch eine Form von Wissen dar und wird zur Unterstützung eingesetzt. So wird beispielsweise die Technologie *Computer Aided Design* (CAD) genutzt, um mit Computern und spezieller Software Produkte zu konstruieren und zu analysieren. Bei der intuitiven Benutzbarkeit ist es von Bedeutung zu betrachten, welche dieser Ebenen angesprochen wird. Aus diesem Grund muss die Erhebung des Vorwissens, und darunter vor allem das Niveau der Expertise in einem bestimmten Bereich, zur Messung der Intuitivität eines Produkts oder Systems erfolgen.

Im Kontext von Prozessmodellen zielt der Großteil der Studien auf die Bewertung der Benutzbarkeit (bzw. Verständlichkeit) verschiedener Modellierungssprachen und damit verbundenen Aspekten ab. Dagegen wird wenig Aufmerksamkeit auf die Bewertung der Intuitivität gelegt, die Berücksichtigung dieses Aspekts ist jedoch entscheidend. Prozessmodelle kommen in Bereichen zum Einsatz, in denen die Prozessausführenden weder über Prozesswissen noch über Vorkenntnisse zum Lesen und Interpretieren solcher Modelle verfügen. Zudem ist es für einen reibungslosen Ablauf in Prozessumgebungen erforderlich, dass Prozessmodelle ohne ausführliche Erläuterungen, also intuitiv verständlich sind. Unter den in Abschnitt 5.1 vorgestellten Ansätzen berücksichtigen nur die Studien in [279] und [131] diesen Aspekt. Sie evaluieren und vergleichen die intuitive Verständlichkeit verschiedener Prozessmodellierungssprachen (Kategorie 1 in Abschnitt 5.1). Für diese Arbeit sind allerdings Ansätze von besonderer Bedeutung, die verschiedene Repräsentationsformate zur Darstellung von Prozessen untersuchen (Kategorie 3). Aufgrund der beschränkten Ausdruckskraft von Prozessmodellierungssprachen können Prozessdetails nicht angemessen in Prozessmodellen dargestellt werden. Der Versuch, diese Details in den Kontrollfluss zu integrieren, führt in bestimmten Szenarien zu umfangreichen, überladenen und schwer verständlichen Modellen. Um diesen Aspekt zu adressieren, müssen alternative Repräsentationsformate im Sinne von nicht-textuellen Aufgabenanweisungen in Betracht gezogen werden. Beispielsweise können Bilder oder Videos die Darstellung von komplexen Aufgabenanweisungen unterstützen [282]. Empirische Untersuchungen zur Intuitivität unterschiedlicher Repräsentationsformate sind eine bislang unerforschte Thematik. Diese Forschungslücke wird durch die Konzeption und Durchführung einer eigenen Studie im Kontext von Aufgabenannotationen geschlossen.

5.2.2 STUDIENDESIGN, FORSCHUNGSFRAGEN UND HYPOTHESEN

Bei der Konzeption dieser Studie werden die Ergebnisse, Herangehensweisen und Erkenntnisse bisheriger Arbeiten berücksichtigt. Die wichtigsten Entscheidungen hinsichtlich des Studiendesigns sind im Folgenden zusammengefasst:

1. Die Studie fokussiert die Evaluation der Intuitivität verschiedener Repräsentationsformate von Aufgabenannotationen. Bei der Bewertung des Vorwissens der StudienteilnehmerInnen im Bereich Prozessmodellierung und -ausführung dienen existierende Studien als Vorlage [90, 169, 228, 279]. Im Gegensatz zu bisherigen Ansätzen werden die drei Aspekte der intuitiven Benutzbarkeit (Effektivität, mentale Effizienz, Zufriedenheit) getrennt erhoben. Dabei gilt eine Aufgabenannotation als intuitiv benutzbar

bzw. verständlich², wenn sie in allen drei Dimensionen hohe Werte erzielt. Darüber hinaus ermöglicht die separate Bewertung aller Aspekte, die Ursachen möglicher Probleme hinsichtlich der Gebrauchstauglichkeit zu identifizieren.

2. In [278] wird eine Toolbox mit Fragebögen zur Evaluation der drei Intuitivitäts-Aspekte zur Verfügung gestellt. Sie ist als allgemein anwendbares Instrument zur Bewertung von Software, Anwendungen und technischen Produkten konzipiert. Dabei haben sich die enthaltenen Fragebögen bereits in vielen verschiedenen Anwendungs- und Forschungsbereichen bewährt, z.B. in der Interaktion mit mobilen Geräten [178] oder der Roboterprogrammierung [189]. Ihre breite Einsetzbarkeit sowie die detaillierten Beschreibungen zur Anwendung führen zur Entscheidung, die Messinstrumente und das damit verbundene Studienkonzept auf die systematische Evaluierung von Aufgabenannotationen zu übertragen. Die Verwendung bereits entwickelter Methoden ermöglicht außerdem einen Vergleich der Studienergebnisse mit vorhandener sowie zukünftiger Forschung innerhalb des aktuellen Forschungsfelds und anderen Bereichen.
3. Gemäß [97] kann Verständlichkeit nur indirekt entweder durch Verständnisfragen oder anhand der Durchführung von Problemlösungsaufgaben gemessen werden. Aufgrund der höheren Anforderungen an das Studiendesign existieren in bisherigen Arbeiten deutlich weniger Ansätze hinsichtlich des letzten Aspekts. Angeregt durch die Ergebnisse in [90], die derartige Ansätze für zukünftige Arbeiten nahelegen, wird im Rahmen der in dieser Arbeit konzipierten Studie die Intuitivität von Aufgabenannotationen durch einen experimentellen Aufbau evaluiert. StudienteilnehmerInnen müssen eine Reihe von Aufgaben bewältigen und werden dabei beobachtet und anschließend befragt. Die verwendete Fragebogentoolbox von [278] ist zudem speziell für Studien entwickelt worden, in denen Aufgaben praktisch gelöst oder ausgeführt werden.
4. In [90] wird vorgeschlagen, neben textuellen und diagrammbasierten Darstellungen auch andere Formate zu evaluieren. In Anlehnung an diese Idee und dem Ansatz in [282] werden im Rahmen der experimentellen Evaluation Bilder als weiteres Repräsentationsformat für Annotationen untersucht. Folglich werden in diesem Studiendesign textuelle, diagramm- und bildbasierte Annotationen evaluiert und verglichen.
5. In [90, 214] wird der Zusammenhang verschiedener Aufgabenstellungen mit bestimmten Repräsentationsformaten diskutiert. Diesem Aspekt folgend, werden in dieser Arbeit nicht nur diverse Repräsentationsformate der Aufgabenannotationen untersucht, sondern auch in Verbindung mit unterschiedlichen Aufgabenstellungen evaluiert.

²Im Rest des Kapitels werden im Kontext von Aufgabenannotationen oder Prozessmodellen die Begriffe ‚Verständlichkeit‘, ‚Gebrauchstauglichkeit‘ und ‚Benutzbarkeit‘ synonym verwendet.

6. Die Ergebnisse in [279] legen nahe, dass der Bildungsgrad von Personen einen Einfluss auf ihr Verständnis von Prozessmodellen hat. Inspiriert durch diese Untersuchung, wird auch in der hier konzipierten Studie der Bildungsgrad (repräsentiert durch den höchsten formalen Bildungsabschluss) der StudienteilnehmerInnen erhoben und bzgl. seines Einflusses auf die intuitive Benutzbarkeit von Aufgabenannotationen evaluiert.

Anhand dieser Vorüberlegungen zum Studiendesign werden Forschungsfragen (FF) und damit verbundene Hypothesen formuliert. Sie werden im Rahmen der Studie überprüft und sind im Folgenden zusammengefasst.

FF1 *Welches Repräsentationsformat (Text, Bild, Diagramm) von Aufgabenannotationen ist am intuitivsten?*

Basierend auf den Erkenntnissen von [91, 228, 279] lassen sich drei Hypothesen zu dieser Frage ableiten:

Hypothese 1a: Diagrammbasierte Darstellungen von Aufgabenannotationen sind intuitiv verständlicher als textbasierte Darstellungen.

Hypothese 1b: Vorwissen in der Prozessmodellierung und -ausführung hat einen Einfluss auf die intuitive Verständlichkeit von diagrammbasierten Aufgabenannotationen.

Hypothese 1c: Die intuitive Verständlichkeit eines bestimmten Repräsentationsformats hängt vom Bildungsgrad der ProzessteilnehmerInnen ab.

FF2 *Gibt es Repräsentationsformate von Aufgabenannotationen, die für eine bestimmte Aufgabenstellung intuitiv verständlicher sind als andere?*

Aufgrund der Ergebnisse in [90] wird folgende Annahme getroffen:

Hypothese 2: Je nach Aufgabenstellung sind Aufgabenannotationen in bestimmten Repräsentationsformaten intuitiv verständlicher.

5.2.3 MESSINSTRUMENTE UND AUFGABEN

In den nachfolgenden Abschnitten erfolgt zunächst eine detaillierte Darlegung der verwendeten Fragebögen und Methoden zur Evaluierung der Intuitivität von Aufgabenannotationen. Die Auswertungen der Fragebögen sind später in Abschnitt 5.3 zu finden. Weiter werden im Folgenden die konzipierten Aufgaben erläutert, wobei unterschiedliche Aufgabenstellungen und Repräsentationsformate berücksichtigt werden. Angelehnt an den Metallspritzgussprozess und den Szenarien aus Abschnitt 4.3 umfassen alle Aufgabenstellungen Platzierungstätigkeiten bestimmter Bauteile, allerdings unter Berücksichtigung

verschiedener Aspekte und Bedingungen. Zum einen wird durch diese Vorgehensweise untersucht, wie die in den Experimenten in Kapitel 4 analysierten relevanten Prozessdetails verständlich in Prozessmodellen dargestellt werden können. Zum anderen werden so die verschiedenen Repräsentationsformate möglichst authentisch im Kontext realer Prozessschritte und dort verwendeter Objekte evaluiert. Dieser Aspekt ist vor allem für die Anwendung des Gesamtkonzepts und damit auch des Annotationsschritts in der Praxis von Bedeutung. Alle in der Studie verwendeten Materialien sind im **Anhang** dieser Arbeit und auf GitHub³ zu finden. Bei der Entwicklung der Fragebögen ist vorwiegend auf die bereitgestellte Toolbox von [278] zurückgegriffen und der Kontext der Prozessmodellierung und -ausführung berücksichtigt worden. Die Einsatzzeitpunkte der Fragebögen während des Studienablaufs sind in Abschnitt 5.2.4 erläutert.

5.2.3.1 VORWISSEN UND DEMOGRAFISCHER HINTERGRUND

Vorkenntnisse der StudienteilnehmerInnen bzgl. Prozessmodellierung und -ausführung sowie demografische Daten (Alter, Geschlecht, höchster Schulabschluss, Fachrichtung, Position und Berufserfahrung) werden mithilfe von Fragebogen 1 (F1) interviewgestützt erhoben (Anhang A1). Falls die Teilnehmenden im Umgang mit Prozessmodellen vertraut sind, werden sie auch gebeten anzugeben, wie lange sie bereits mit Prozessmodellen arbeiten und ob dabei der Fokus auf der Modellierung von Prozessen, ihrer Ausführung oder beidem liegt. Zudem werden die StudienteilnehmerInnen in diesem Kontext befragt, welche Art von Anleitung sie im Allgemeinen bevorzugen, um sich selbst neues Wissen anzueignen oder sich eine Aktivität beizubringen. Hierbei werden sie aufgefordert, die drei Anleitungsformate – textgestützt, bildgestützt sowie diagramm- bzw. listengestützt – in eine von ihnen bevorzugte Reihenfolge zu bringen. Die Evaluation dieser Aspekte ist angelehnt an die Unterscheidung verschiedener Lerntypen [179]. Ziel ist zu untersuchen, ob die Affinität zu einem bestimmten Anleitungsformat im Zusammenhang mit der beurteilten Intuitivität der verschiedenen Darstellungsarten von Aufgabenannotationen steht.

5.2.3.2 EFFEKTIVITÄT, MENTALE EFFIZIENZ, ZUFRIEDENHEIT

Effektivität. Das Ergebnis einer Prozessausführung wird von dem Moderator bzw. der Moderatorin hinsichtlich **Genauigkeit und Vollständigkeit (GUV)** mit Fragebogen 2a (F2a) quantifiziert (Anhang A2). Die Genauigkeit beschreibt, wie gezielt und selbstständig die TeilnehmerInnen eine Aufgabe abschließen. Sie wird mit vier Abstufungen erfasst. Maximal können 3 Punkte („Der Nutzer/Die Nutzerin führte die Aufgabe ohne Probleme

³https://github.com/MyFi-UBT/thesis_implementation, zuletzt besucht: 01.03.2024.

aus.“) und minimal 0 Punkte erreicht werden („Der Nutzer/Die Nutzerin hat die Aufgabe mit permanenter Unterstützung des Moderators/der Moderatorin bearbeitet.“). Die Dimension der Vollständigkeit wird anhand von drei Ausprägungen mit 2 Punkten („Die Aufgabe wurde vollständig erfüllt.“), 1 Punkt („Die Aufgabe wurde teilweise erfüllt.“) und 0 Punkten bewertet („Die Aufgabe wurde nicht erfüllt.“). Die Summe der erzielten Punkte in Genauigkeit und Vollständigkeit repräsentiert die Effektivität einer Aufgabenausführung. Sie wird als Prozentsatz ausgedrückt, wobei 100% Effektivität (d.h. 5 Punkte) einer fehlerfreien und selbstständigen Aufgabenausführung entspricht. Im Gegensatz dazu repräsentieren 0% (d.h. 0 Punkte) nicht erfolgreich ausgeführte Aufgaben, die trotz der fortwährenden Unterstützung durch den Moderator bzw. die Moderatorin fehlschlagen.

Mentale Effizienz. Die StudienteilnehmerInnen bewerten ihre mentale Anstrengung einer Aufgabenausführung anhand Fragebogen 2b (F2b, Anhang A3). Die **Skala zur Erfassung von subjektiv erlebter Anstrengung (SEA)** ist als 220-Punkte-Skala konzipiert und umfasst sieben Termini, welche von „kaum anstrengend“ bis „außerordentlich anstrengend“ reichen [73]. Die TeilnehmerInnen werden instruiert, eigenständig einen Punkt auf der Skala zu kennzeichnen, der ihrer subjektiv wahrgenommenen Anstrengung während der Durchführung der Aufgaben entspricht. Anhand der Markierung kann dann die subjektiv wahrgenommene **mentale Anstrengung** abgelesen werden, wobei niedrige Punktzahlen und somit ein geringer wahrgenommener Aufwand eine hohe **mentale Effizienz** in Hinblick auf die Benutzbarkeit eines Prozessmodells bedeuten.

Zufriedenheit. Die Zufriedenheit der TeilnehmerInnen mit der Aufgabenbearbeitung wird mit Fragebogen 2c (F2c) bzw. mit dem **Questionnaire for the subjective consequences of intuitive use (QUESI)** erhoben [120] (Anhang A4). Er wird von den Studienteilnehmenden selbst ausgefüllt. Mit dem Fragebogen werden die subjektiven Konsequenzen intuitiver Benutzung durch 14 Fragen zu den Aufgabenanweisungen gemessen. Sie können auf einer 5-Punkte-Likert-Skala von „trifft gar nicht zu“ bis „trifft völlig zu“ beantwortet werden. Eine **Aufgabenanweisung** ist in dieser Studie als Beschreibung eines Prozessschritts inklusive einer Aufgabenannotation definiert. Jede Frage ist einem der fünf Kriterien subjektiver Folgen der Nutzung zugeordnet:

1. Niedrig wahrgenommene kognitive Beanspruchung (Fragen 1, 6, 11),
2. Hohe wahrgenommene Zielerreichung (Fragen 2, 7, 12),
3. Niedrig wahrgenommener Lernaufwand (Fragen 3, 8, 13),
4. Hohe Vertrautheit (Fragen 4, 9, 14),
5. Niedrig wahrgenommene Fehlerrate (Fragen 5, 10).

Die zugehörigen Fragen sind so formuliert, dass höhere Werte bessere Ergebnisse bedeuten. Der Mittelwert aller Kriterien ergibt den sog. **QUESI-Score**, wobei hohe Werte mit steigender Zufriedenheit korrelieren.

5.2.3.3 INTERPRETATION DER AUFGABENANWEISUNGEN

In einer Vorstudie mit fünf Personen wurde die **Think-Aloud-Methode** [72] eingesetzt, um vertiefte Einblicke in die kognitiven Prozesse der ProbandInnen zu gewinnen. Bei dieser Methode sprechen Personen ihre Gedanken während der Aufgabenbearbeitung laut aus. Aus den so geäußerten Kommentaren ergibt sich die Schlussfolgerung, dass die Aufgabenanweisungen unterschiedlich interpretiert werden können. In der Vorstudie beeinträchtigte dies zwar in vielen Fällen nicht den Erfolg der Aufgabenbearbeitung, führte jedoch zu einer Einschränkung des möglichen Lösungsraums. Einige Personen interpretierten bildgestützte Aufgabenannotationen beispielsweise als konkrete Anweisungen, wo und wie genau Bauteile platziert werden sollen. Es wurden auch Diskussionen beobachtet, ob eine vorgeschriebene Reihenfolge für das Platzieren der Bauteile besteht. In den Aufgabenanweisungen wurden die zu verwendenden Werkstücke bzgl. ihres Namens alphabetisch sortiert (vgl. Stapelaufgabe in Abschnitt 5.2.3.4). Obwohl das Aufgabendesign keine beabsichtigten und expliziten Anweisungen diesbezüglich vorgesehen hatte, wurde ihre Reihenfolge von einigen TeilnehmerInnen als möglicherweise verbindlich diskutiert. Von anderen wurde sie bei der Ausführung strikt übernommen.

Auf Basis der so gewonnenen Erkenntnisse ist Fragebogen 3 (F3) für den Einsatz in der Studie entwickelt worden. Mit ihm werden TeilnehmerInnen nach ihren **Interpretationen** bzgl. der Aufgabenanweisungen befragt (Anhang A5). Nach einer Aufgabenausführung wird erhoben, ob die folgenden vier Aspekte auf eigenen Entscheidungen oder auf Vorgaben der Aufgabenanleitung beruhen:

- Positionen bestimmter Bauteile in der Szene,
- Positionen bestimmter Bauteile zueinander,
- Ausrichtung bestimmter Bauteile und
- Bearbeitungsreihenfolge bestimmter Bauteile.

Auf welches Bauteil sich eine Frage bezieht, wird situativ entschieden und an den jeweiligen Aufbau angepasst. Im Kontext dieses Fragebogens kann maximal ein Wert von 4 und minimal ein Wert von 0 pro Aufgabe erreicht werden. Der Wert 0 bedeutet, dass die TeilnehmerInnen die Aufgabenanweisung genau wie vom Studiendesign vorgesehen interpretiert haben. Eine davon maximale Abweichung wird mit dem Wert 4 ausgedrückt.

5.2.3.4 AUFGABENSTELLUNGEN

Den Szenarien und dem Beispielprozess aus Abschnitt 4.3 folgend liegt der Fokus der Studie auf der Untersuchung von Annotationen für Prozessmodelle aus der Fertigungsindustrie. Diese enthalten oft Anweisungen zur Manipulation von Objekten im Arbeitsbereich. Inspiriert durch die Studie in [188] sind drei Aufgabenstellungen konzipiert worden, die typische Aktivitäten solcher Prozessdomänen reflektieren [137]: (i) **Platzieren**, (ii) **Stapeln** und (iii) **Sortieren**.

Beispielsweise müssen im Metallspritzgussverfahren mehrmals Bauteile von einer Platte auf einer anderen platziert werden. In anderen Szenarien, z.B. in der Lebensmittelindustrie, müssen Produkte geeignet gestapelt werden. Dabei liegt der Fokus darauf, dass Platz gespart wird, die Struktur unter der Last nicht zusammenbricht oder eine gegenseitige Beeinträchtigung der Produkte vermieden wird. Das Sortieren von Objekten ist ebenso häufig ein integraler Bestandteil von Prozessausführungen, wie etwa im Bereich der Lagerverwaltung.

Um den Studienaufbau realistischer zu gestalten, werden Materialien aus realen Prozessumgebungen verwendet. Dies sind Metallbauteile unterschiedlicher Größen und Formen (z.B. Zahnräder oder Zahnriemenscheiben), industrielle Lagerbehälter in drei verschiedenen Farben und eine Metallplatte (in den Aufgaben als ‚Palette‘ bezeichnet). Außerdem liegt den StudienteilnehmerInnen ein Tablet vor, auf welchem die Aufgaben nacheinander angezeigt werden. Der Studienaufbau und alle in der Studie verwendeten Materialien sind Abbildung 30 zu entnehmen. Die Fragebögen werden separat aufbewahrt und zu bestimmten Zeitpunkten ausgehändigt. Jedes Bauteil ist mit einem kleinen Aufkleber versehen, der einen Buchstaben (A-H) zeigt, um seine Identifikation zu erleichtern (vgl. Abbildung 30b). In der Vorstudie wurden in den Aufgaben die Bauteile mit ihrer technischen Bezeichnung verwendet. Allerdings waren TeilnehmerInnen ohne tech-



(a) Aufbau zu Beginn der Studie.

(b) Beschriftete Bauteile (A-H).

Abbildung 30: Studienaufbau mit Materialien aus realen Prozessumgebungen.

	<i>Prozessschritt</i>	<i>Aufgabenannotation</i>
Platzieren	Platziere Bauteile A, B, D, E, G und H auf Palette	Platziere Bauteil A im oberen oder im unteren Viertel der Palette
Stapeln	Staple Bauteile D, E, F auf Palette aufeinander und Bauteile B, G auf Palette aufeinander	Platziere Bauteil E , darauf D , darauf F und platziere Bauteil B , darauf G
Sortieren	Sortiere Bauteile A, B, C, D, F, G in Boxen	Sortiere Bauteil A, F in blaue, B, C in rote und D, G in grüne Box

Tabelle 5.1: Verschiedene Aufgabenstellungen, bestehend aus abstrakten Prozessschrittbeschreibungen und konkretisierenden Aufgabenannotationen nach [80].

nisches Fachwissen nicht in der Lage, die Begriffe den Werkstücken korrekt zuzuordnen, weshalb eine Vereinfachung hinsichtlich dieses Aspekts erfolgt.

Die drei Aufgabenstellungen umfassen Arbeitsanweisungen zu inhaltlich unterschiedlichen Tätigkeiten. Wie vorab erläutert, setzt sich eine Aufgabenanweisung jeweils aus einer abstrakten Beschreibung (Prozessschritt) und einer Menge von Prozessdetails (Aufgabenannotation) zusammen. Dem Prozessschritt sind lediglich grob die auszuführende Tätigkeit und die Objekte zu entnehmen, die in diesem Schritt berücksichtigt werden müssen. Die Aufgabenannotation spezifiziert die Anweisung unter Verwendung von Prozessdetails und gibt nähere Informationen zur Platzierungsregion oder anderen relevanten Aspekten. In Tabelle 5.1 sind die drei verschiedenen Aufgabenstellungen zusammengefasst. Jede Aufgabenstellung legt den Schwerpunkt auf einen bestimmten Aspekt, nämlich die präzise Platzierung eines Objekts im Arbeitsbereich (Platzieren), die räumliche Anordnung mehrerer Objekte zueinander (Stapeln) sowie die systematische Reihenfolge und Zuordnung von Objekten entsprechend festgelegter Kriterien (Sortieren). Zum erfolgreichen Abschluss einer Aufgabe müssen dabei je nach Aufgabenstellung folgende Kriterien erfüllt sein:

1. Die **Platzierungsaufgabe** gilt als erfolgreich abgeschlossen, wenn Bauteil A im oberen oder im unteren Viertel der Palette liegt. Die exakte Position und Orientierung von Bauteil A sowie die der anderen Bauteile hat dabei keinen Einfluss auf den Erfolg.
2. Für die **Stapelaufgabe** müssen zwei Stapel auf der Palette gebildet werden. Der eine Stapel besteht dabei von unten nach oben aus den Bauteilen E, D und F. Der andere Stapel umfasst von unten nach oben die Bauteile B und G. Das Einhalten der Platzierungsreihenfolgen innerhalb der Stapel ist für die Erfüllung der Aufgabe verpflichtend. Welcher der beiden Stapel zuerst aufgebaut wird, kann dagegen beliebig bestimmt

werden. Auch die Positionen der Stapel auf der Palette sowie die Orientierungen der Bauteile sind nicht von Bedeutung.

3. Nach Bearbeitung der **Sortieraufgabe** müssen sich die Bauteile A und F in der blauen Box, B und C in der roten Box und D und G in der grünen Box befinden. Die genaue Position oder Orientierung der Bauteile in den Boxen ist nicht durch die Anweisung vorgegeben und darf für eine erfolgreiche Aufgabenerfüllung beliebig gewählt werden. Auch die Reihenfolge, in der die Boxen befüllt werden, nimmt keinen Einfluss auf den Erfolg. Allerdings muss die Befüllung einer Box atomar erfolgen. Zum Beispiel werden die Bauteile D und G nacheinander in die grüne Box platziert und der Vorgang darf nicht durch die Platzierung von Bauteil A in die blaue Box unterbrochen werden.

Diese Aufgabenziele sind vor allem im Zusammenhang mit der Aufgabeninterpretation von Bedeutung (Abschnitte 5.2.3.3 und 5.3.1.2). Um aus diesen Aufgabenstellungen im Kontext der Studie bearbeitbare Aufgaben für die StudienteilnehmerInnen bereitzustellen, wird für jede Aufgabenstellung ein BPMN-Prozessmodell erstellt. Die Bearbeitung einer Aufgabe besteht damit in der Ausführung des präsentierten Prozessmodells. Jedes BPMN-Prozessmodell umfasst insgesamt die folgenden drei Prozessschritte, wobei der zweite Prozessschritt je nach Aufgabenstellung abweicht:

- (1) „Nimm alle Bauteile aus Kiste“,
- (2) **Platzieren, Stapeln** oder **Sortieren** der Bauteile mit entsprechender Annotation und
- (3) „Lege verbleibende Bauteile zurück in Kiste“.

Ein Beispiel, wie diese Schritte in einem Prozessmodell abgebildet werden, ist in Abbildung 31 im Kontext des nächsten Abschnitts zu finden.

5.2.3.5 REPRÄSENTATIONSFORMATE

Die Ergebnisse vorheriger Arbeiten zeigen, dass die Bewertung eines Repräsentationsformats mit der Aufgabenstellung zusammenhängt [90]. Aus diesem Grund werden Aufgabenannotationen in verschiedenen Repräsentationsformaten pro Aufgabenstellung zu Prozessschritt (2) untersucht (Platzieren, Stapeln, Sortieren). Damit kann überprüft werden, ob es hinsichtlich der intuitiven Benutzbarkeit Zusammenhänge zwischen den inhaltlichen und repräsentativen Aspekten einer Aufgabenanweisung gibt. Insgesamt werden in dieser Studie drei unterschiedliche Repräsentationsformate zu Aufgabenannotationen betrachtet: (i) **Text**, (ii) **Bild** und (iii) **Diagramm**.

Für jede Aufgabenstellung und jedes Repräsentationsformat wird ein Prozessmodell entwickelt. Insgesamt werden somit neun Prozessmodelle erstellt, die jeweils eine dieser

PROZESSMODELLE/ AUFGABEN		REPRÄSENTATIONSFORMAT DER AUFGABENANNOTATION (1-3)		
		Text (1)	Bild (2)	Diagramm (3)
AUFGABENSTELLUNG (A-C)	Platzieren (A)	A1	A2	A3
	Stapeln (B)	B1	B2	B3
	Sortieren (C)	C1	C2	C3

Tabelle 5.2: Überblick der neun Prozessmodelle mit eindeutigen Bezeichnungen.

Kombinationen enthalten. Tabelle 5.2 gibt einen Überblick über die Prozessmodelle. Zur besseren Identifikation hat jedes der Modelle eine eindeutige Bezeichnung, bestehend aus einem Buchstaben für eine bestimmte Aufgabenstellung und einer Zahl für eines der Repräsentationsformate. Wie bereits erläutert, bildet jedes Prozessmodell den gesamten Prozess ab und enthält damit immer drei Schritte (inklusive Prozessschritt (1), d.h. alle Bauteile aus der Kiste zu nehmen, und (3), d.h. sie wieder in die Kiste zurückzulegen). Das Prozessmodell selbst ist stets diagrammatisch dargestellt. Abhängig von dem gewählten Format der Aufgabenannotation variiert die Darstellung von Prozessschritt (2) im Modell. Abbildung 31 zeigt beispielhaft Prozessmodell C2, das die Sortieraufgabe mit der bildbasierten Aufgabenannotation enthält. Die spezifische Darstellung der Annotationen in den Modellen ist in Kooperation mit ExpertenInnen aus dem Bereich Prozessmodellierung entwickelt worden. Alle Modelle sind im [Anhang](#) dieser Arbeit zu finden.

Die StudienteilnehmerInnen bearbeiten im Rahmen des Experiments jeweils drei Aufgaben bzw. führen drei Prozessmodelle aus. Dabei unterscheidet sich jede der Aufgaben in Aufgabenstellung und Repräsentationsformat. Zur Eliminierung potenzieller Reihenfolgeeffekte und zur Gewährleistung einer gleichmäßigen Verteilung bzgl. der verschiedenen Kombinationen, werden die TeilnehmerInnen zu Beginn der Studie bestimmten Gruppen zugewiesen. Jede Gruppe umfasst drei Prozessmodelle, für die eine Reihenfolge vordefiniert ist. Beispielsweise sind Gruppe 1 die Modelle A1, B2, C3 oder Gruppe 2 die Modelle B1, C2, A3 zugeordnet. Um sämtliche Reihenfolgen und Kombinationen abzudecken, müssen theoretisch 18 Gruppen gebildet werden. Aufgrund von Einschränkungen bzgl. des Umfangs der Studie werden neun zufällige Gruppen aus den insgesamt 18 ausgewählt. Diese Methode scheint am besten geeignet, um den Auswirkungen von Reihenfolgeeffekten unter begrenzten Ressourcen entgegenzuwirken.

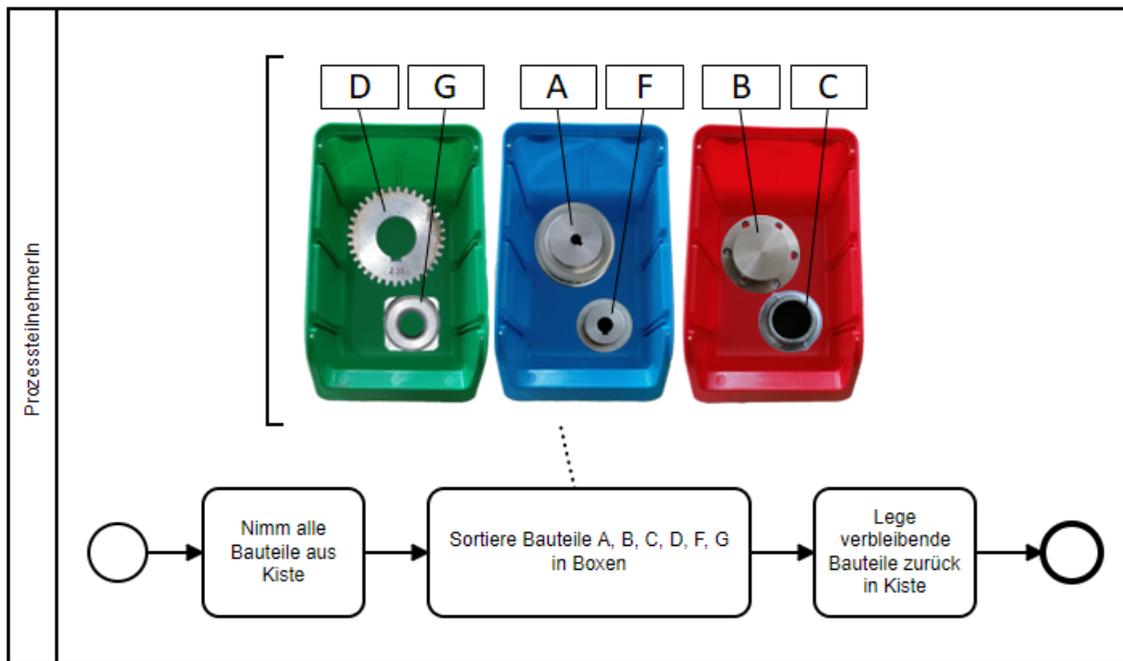


Abbildung 31: Modell C2 mit Sortieraufgabe und bildgestützter Aufgabenannotation.

5.2.3.6 DIREKTER VERGLEICH VON PROZESSMODELLEN

Zum weiteren Vergleich verschiedener Repräsentationsformate von Aufgabenannotationen wird eine Zusatzaufgabe entwickelt. Dafür werden die drei Prozessmodelle, welche dieselbe Aufgabenstellung in unterschiedlichen Repräsentationsformaten enthalten, gemeinsam in einem neuen Fenster auf dem Tablet abgebildet. Beispielsweise zeigt solch eine Darstellung die Prozessmodelle C1, C2, C3 untereinander. Die gezeigten Seiten mit den Prozessmodellen zu allen Aufgabenstellungen sind in den Anhängen **B1**, **B2** und **B3** zu finden. Die StudienteilnehmerInnen erhalten zufällig eine der Varianten. Sie werden gebeten, alle Prozessmodelle zu betrachten und dasjenige zu nennen, das für sie im direkten Vergleich am einfachsten scheint, um die Aufgabenanweisung zu verstehen.

5.2.4 DURCHFÜHRUNG DER STUDIE UND ABLAUF

Die Durchführung der Studie erfolgte im Zeitraum 02.05.2022 bis 10.06.2022 an Arbeitsplätzen der TeilnehmerInnen, d.h. in Arbeitsräumen und Laboren von Universitäten, Forschungsinstituten und Unternehmen. Die Studie wurde von der Autorin dieser Arbeit in der Rolle der Moderatorin bzw. Interviewerin durchgeführt. Sie war während des gesamten Experiments anwesend, kontrollierte alle Schritte und gewährleistete die Vergleichbarkeit der Ergebnisse. Der Gesamt Ablauf der Studie ist in Abbildung 32 zusammengefasst. Die Studie umfasst drei Teile, einen Einführungsteil, einen Hauptteil mit

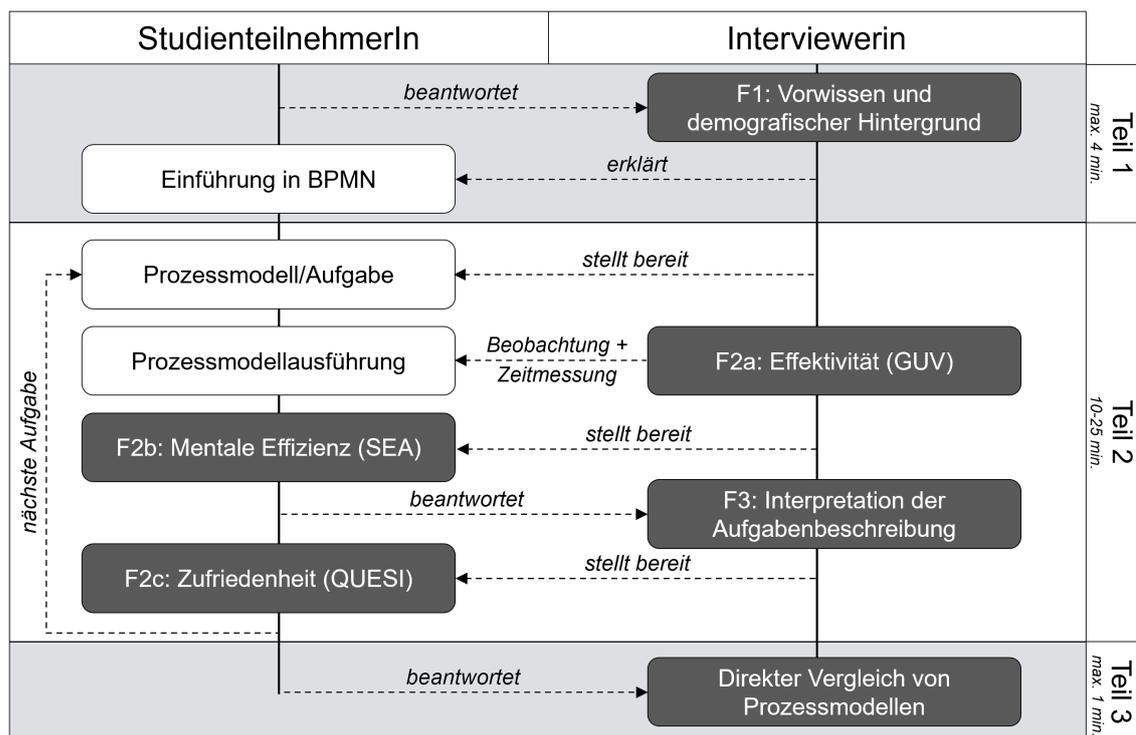


Abbildung 32: Überblick des dreiteiligen Studienablaufs; Messinstrumente sind in dunkelgrauer Farbe hervorgehoben.

Aufgabenbearbeitung- und beurteilung und einen Abschlussteil. Ein kompletter Durchlauf aller Abschnitte dauerte im Durchschnitt 23 Minuten.

Zu Beginn wurde den TeilnehmerInnen kurz der Hintergrund der Studie erläutert. Anschließend erfolgte die Befragung mit Fragebogen F1 zur Erfassung ihrer Erfahrungen mit Prozessmodellen, ihrem bevorzugten Repräsentationsformat für Anleitungen und demografischer Daten. Im Anschluss wurde innerhalb von maximal zwei Minuten die grundlegende Idee der Prozessmodellierung erläutert. Dabei wurden wesentliche BPMN-Elemente anhand exemplarischer BPMN-Diagramme auf dem Tablet erklärt.

Der zweite Teil der Studie wurde mit einer Beschreibung des Studienaufbaus und der zu Verfügung stehenden Materialien eingeleitet. Anschließend wurde mit der Bearbeitung der ersten Aufgabe begonnen. Dafür wurde den TeilnehmerInnen das erste Prozessmodell auf einem handelsüblichen Tablet gezeigt und sie wurden gebeten, das dargestellte Prozessmodell auszuführen. Dabei maß die Interviewerin die Ausführungszeit und leistete Unterstützung, wenn nötig. Außerdem nutzte sie F2a, um das Ergebnis der Ausführung hinsichtlich der Effektivität zu bewerten. Anschließend wurde zur Erhebung der mentalen Effizienz den TeilnehmerInnen F2b ausgeteilt, mit dem sie selbständig ihre wahrgenommene mentale Anstrengung während der Aufgabenausführung beurteilten. Danach stellte die Interviewerin anhand F3 offene Fragen zum Aufbau, um Interpretationen der Auf-

gabenbeschreibungen zu erfassen. Die TeilnehmerInnen erhielten Rückmeldung darüber, ob ihre Prozessausführung erfolgreich war und wurden zur Erfassung ihrer Zufriedenheit gebeten, selbstständig F2c auszufüllen. Dieser zweite Teil der Studie wurde dann für die beiden noch fehlenden Aufgaben wiederholt und wurde mit der Bereitstellung des nächsten Prozessmodells eingeleitet.

Im letzten Teil der Studie wählten die ProbandInnen abschließend ein präferiertes Repräsentationsformat auf Basis des direkten Vergleichs verschiedener Prozessmodelle. Zur nachhaltigen Erhöhung der Teilnahmebereitschaft an Studien wurden Belohnungen (Incentives) von geringfügigem Wert ausgehändigt.

5.3 ERGEBNISSE DER EXPERIMENTELLEN STUDIE

In den folgenden Abschnitten werden die Ergebnisse der Studie präsentiert. Insgesamt erfolgt die methodische Auswertung der Studie zweigeteilt. Im Rahmen deskriptiver Statistik wird zunächst umfassend die Stichprobe der StudienteilnehmerInnen betrachtet. Weiter werden kleinere Analysen zu den sekundären Teilen der Studie vorgestellt und die drei Aspekte der intuitiven Benutzbarkeit deskriptiv betrachtet. Anschließend erfolgt eine empirische Prüfung der aufgestellten Hypothesen aus Abschnitt 5.2.2 und eine detaillierte Auswertung bzgl. der drei Intuitivitäts-Aspekte durch Verwendung geeigneter statistischer Methoden⁴. Dabei werden wichtige Schritte hinsichtlich der Vorgehensweise zur Auswertung der Fragebögen erläutert. Basierend auf diesen Ergebnissen werden Schlussfolgerungen zur Beantwortung der Forschungsfragen der Studie und zur Beurteilung der Intuitivität von Aufgabenannotationen gezogen.

5.3.1 DESKRIPTIVE STATISTIK

In den folgenden Abschnitten wird zunächst die Stichprobe der StudienteilnehmerInnen auf Basis der Auswertung von Fragebogen 1 beschrieben. Im Anschluss folgt eine kurze Betrachtung der Ergebnisse bzgl. der Interpretation der Aufgabenanweisungen (Abschnitt 5.2.3.3), dem direkten Vergleich der Prozessmodelle mit verschiedenen Repräsentationen von Aufgabenannotationen (Abschnitt 5.2.3.6) und der Ausführungszeit. Abschließend werden die Effektivität, mentale Effizienz und Zufriedenheit der StudienteilnehmerInnen im Zusammenhang mit verschiedenen Variablen deskriptiv ausgewertet.

⁴Alle Auswertungen der Studie sind zusammengefasst online zu finden: https://github.com/MyFi-UBT/thesis_implementation, zuletzt besucht: 01.03.2024.

5.3.1.1 STUDIENPOPULATION

Insgesamt nahmen $n = 50$ Personen an der Studie teil. Tabelle 5.3 gibt einen Überblick über die demografische Zusammensetzung der Studienpopulation.

<i>Variable</i>	<i>Ausprägungen</i>	<i>M/Anzahl</i>	<i>SD/Prozent</i>	
Alter	Jahre	35.2 (21-66)	11.4	
Geschlecht	männlich/weiblich/divers	24/26/0	48%/52%/0%	
Höchster Bildungsabschluss	Grund-/Haupt-/Realschule/ Gymnasium/Hochschule	1/3/10/ 9/27	2%/6%/20%/18%/54%	
Berufliche Position	in Ausbildung/Beschäftigt o. PV/ Beschäftigt mit PV/Leitung	7/30/ 10/3	14%/60%/20%/6%	
Berufserfahrung	Jahre	10.8	10.3	
Fachrichtung	Ingenieurwesen und IT/Gesundheit/Wirtschaft u. Politik/Medien/Handwerk/Andere	13/13/ 12/6/ 3/3	26%/26%/24%/12%/6%/6%	
	Bevorzugte Anleitung	Textuell/Bildlich/ Diagramm- oder Listenbasiert	7/29/ 14	14%/58%/28%
	Vorwissen			
<i>Modellierung o. Ausführung</i>	ja/nein	26/24	52%/48%	
<i>Erfahrung</i>	Jahre	5.0	5.3	
<i>Kontext</i>	Modellierung/Ausführung/Beides	8/2/16	16%/4%/32%	

Tabelle 5.3: Demografische Daten der StudienteilnehmerInnen.

Die in der Studie verwendeten Materialien standen ausschließlich in deutscher Sprache zur Verfügung, Die Fähigkeit, Deutsch fließend zu lesen und zu sprechen, stellte daher eine notwendige Bedingung für die Teilnahme dar. Die StudienteilnehmerInnen wurden über berufliche und persönliche Netzwerke rekrutiert. Die Stichprobe war hinsichtlich aller demografischer Aspekte heterogen, einschließlich Alter, Geschlecht, beruflichem Schwerpunkt, Bildungsniveau und Expertise im Umgang mit Prozessmodellen. Diese Heterogenität wurde aufgrund zwei maßgeblicher Überlegungen angestrebt:

1. Die Studie fokussiert sich auf ein intuitives Verständnis von Aufgabenannotationen, weshalb die Vorkenntnisse von StudienteilnehmerInnen im Bereich Prozessmodellierung und -ausführung eine große Rolle spielen. Die Betrachtung der Ergebnisse bzgl. dieses Kriteriums im Vergleich ermöglicht eine genauere Einschätzung der Intuitivität. Bei der Studienpopulation ist deshalb sichergestellt worden, dass beide Erfahrungsniveaus gleichmäßig repräsentiert sind. Dabei sind TeilnehmerInnen, die bereits Prozessmodelle für bestimmte Zwecke erstellt oder ausgeführt haben, unabhängig von der Art der verwendeten Modellierungssprache als Personen mit Vorkenntnissen klassifiziert

worden. Innerhalb der Stichprobe ergaben sich 26 Personen mit und 24 Personen ohne Erfahrung in der Erstellung oder Ausführung von Prozessmodellen.

2. Erfahrungen aus industriellen Prozessanwendungen zeigen, dass Personen mit vielfältigen fachlichen Hintergründen in der Ausführung von Prozessmodellen involviert sind. Dies schließt Berufswwechsler oder Quereinsteiger mit unterschiedlichen beruflichen Schwerpunkten ebenso ein wie Personen mit vielseitigen Qualifikationen, Erfahrungen und Vorwissen. Die TeilnehmerInnengruppe der Studie setzte sich aus Personen mit verschiedenen beruflichen Positionen (z.B. Stellen mit oder ohne Personalverantwortung (PV)) und Spezialisierungen zusammen. Darunter vertreten waren die Bereiche Ingenieurwissenschaften, Informationstechnologie, Gesundheitswesen (darunter auch Medizin und Pflege), Wirtschafts- und Rechtswissenschaften, Medien, Handwerk, Sozialforschung und Bildungs- bzw. Erziehungswissenschaften.

5.3.1.2 ERGEBNISSE ZUR INTERPRETATION DER AUFGABENANWEISUNGEN

Interpretationen der StudienteilnehmerInnen bzgl. einer Aufgabenanweisung hängen stark vom gewählten Repräsentationsformat der Aufgabenannotation ab. In jedem Interview wurde mithilfe der formulierten Fragen in F3 erfasst, wie oft eine Handlung von der intendierten Vorgehensweise aufgrund einer anderen Interpretation abwich (Abschnitt 5.2.3.3). Tabelle 5.4 fasst die Ergebnisse durch Betrachtung der verschiedenen Repräsentationsformate in Verbindung mit der Aufgabenstellung zusammen. Hohe Werte bedeuten, dass TeilnehmerInnen die Aufgabenannotationen wie beabsichtigt interpretieren (Wertbereich von 0 bis 4). Die Ergebnisse zeigen, dass vor allem die bildlichen Darstellungen abweichend interpretiert werden. Im Durchschnitt werden bei den bildgestützten Aufgabenanweisungen mit einem Wert von 0.9 im Vergleich zu Texten ($M = 0.3$) und Diagrammen

		Aufgabenstellung		
		Platzieren ($M=0.4$)	Stapeln ($M=0.7$)	Sortieren ($M=0.4$)
Repräsentation	Text ($M=0.3$)	0.6	0.3	0.1
	Bild ($M=0.9$)	0.4	1.4	0.9
	Diagramm ($M = 0.2$)	0.3	0.3	0.1



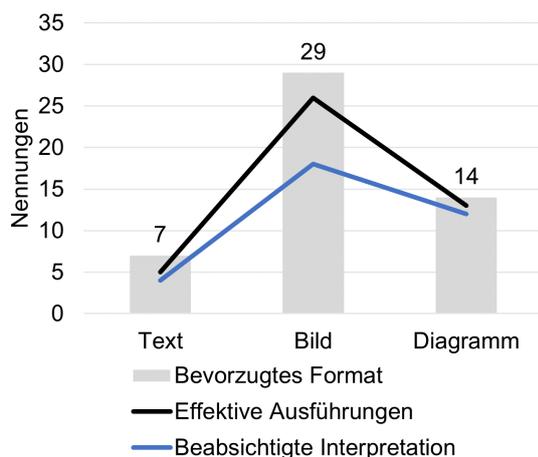
Tabelle 5.4: Abweichende Interpretationen der Aufgabenanweisungen im Durchschnitt.

Abbildung 33: Beispiel einer Ausführung zu Modell A1.

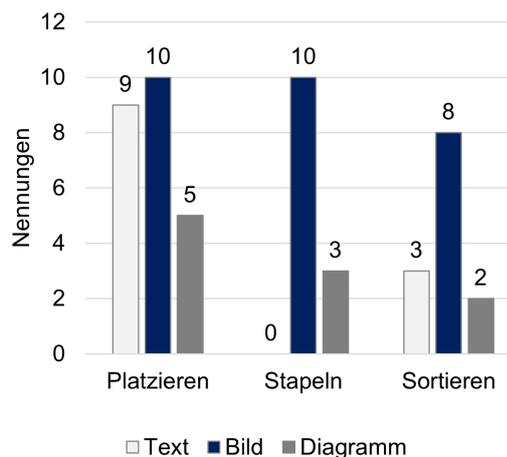
($M = 0.2$) mindestens dreimal so viele Abweichungen bzgl. der Interpretation festgestellt. Darunter ist vor allem die Anweisung der Stapelaufgabe mit einem durchschnittlichen Wert von 1.4 führend. Entgegen der intendierten Aufgabenanweisung (Abschnitt 5.2.3.4) gaben StudienteilnehmerInnen häufig an, dass die exakte Position der Bauteile durch das Bild vorgegeben sei, d.h. die Bauteile müssten mittig übereinander in der gezeigten Orientierung gestapelt werden. Ähnlich wurde die bildliche Aufgabenanweisung im Kontext der Sortieraufgabe interpretiert und erzielt deshalb den zweitgrößten Wert von 0.9. Auch in diesem Kontext wurde häufig versucht, die exakte Position und Orientierung der Bauteile wie auf dem Bild gezeigt zu replizieren. StudienteilnehmerInnen nannten die Positionen und Orientierungen der Bauteile als verpflichtend für die Aufgabenerfüllung. Deutlich weniger Abweichungen sind bei Aufgabenanweisungen in anderen Repräsentationsformaten festzustellen. Unter diesen erzielt die Platzierungsaufgabe mit einer textuellen Aufgabenannotation den höchsten Wert von 0.6. Bei dieser Darstellung wurden häufig vermeintlich verpflichtende Platzierungsreihenfolgen (alphabetisch) sowie die Isolation des Bauteils A von den anderen Bauteilen interpretiert. Allerdings wurde auch unter den TeilnehmerInnen, die letzteres nicht als verpflichtend ansahen, Bauteil A in fast allen Fällen in die eine Hälfte der Palette und die anderen Bauteile als Gruppe in die andere Hälfte platziert. Die ProbandInnen gaben an, dass sie diesen Aufbau trotzdem bewusst gewählt hatten, um die in der Anweisung enthaltene Bedingung sicher zu erfüllen. Lediglich ein Studienteilnehmer nutzte, so wie in Abbildung 33 zu sehen, die gesamte Palette zur Verteilung der anderen Bauteile. Daraus ist zu schließen, dass trotz der korrekten Interpretation einer Anweisung bestimmte Handlungen zum Zeitpunkt der Ausführung entschieden werden, die nicht in der Anweisung enthalten sind.

5.3.1.3 ANLEITUNGSPRÄFERENZEN UND MODELLVERGLEICH

Insgesamt präferieren 58% der StudienteilnehmerInnen bildbasierte Anleitungen, um sich neue Aktivitäten beizubringen. Unter den verbleibenden ProbandInnen bevorzugen 28% diagrammbasierte und 14% textbasierte Anleitungen für diesen Zweck. Die Experimente zeigen, dass die Teilnehmenden auch im Kontext von Prozessmodellen erfolgreich mit ihrem bevorzugten Format arbeiteten (vgl. Abbildung 34a). Dies lässt sich durch die Betrachtung der Effektivität (d.h. Vollständigkeit und Genauigkeit) der Aufgabenbearbeitung ableiten. Von den TeilnehmerInnen, die bildgestützte Anweisungen bevorzugten, erzielen 90% auch mit bildbasierten Aufgabenannotationen die höchste Punktzahl bzgl. der Effektivität. Personen mit Präferenz für diagrammbasierte Anweisungen schneiden am besten ab. Dort erzielen 93% den höchsten Wert mit diagrammatischen Annotationen. Unter denjenigen, die textbasierte Anweisungen bevorzugten, erreichen 71% den maximalen



(a) Bevorzugte Anleitungsformate.



(b) Formate im Modellvergleich.

Abbildung 34: Verschiedene Aspekte im Kontext präferierter Anleitungsformate (links) und Repräsentationsformate von Aufgabenannotationen bzgl. verschiedener Aufgabenstellungen im direkten Modellvergleich (rechts).

Effektivitätswert mit ihrer favorisierten Variante. Ein weiterer informativer Aspekt wird durch das erneute Aufgreifen der Anweisungsinterpretation aus dem vorherigen Abschnitt aufgedeckt. Von den Personen, die bildbasierte Anleitungen präferieren und in der Studie maximal effektiv damit arbeiteten, haben 44% andere als beabsichtigte Anweisungen in die Modelle interpretiert. Bei ProbandInnen mit Präferenz für Texte sind dies nur 20% und bei denjenigen, die Diagramme favorisieren, sogar nur 8%. Weiter kann angenommen werden, dass Personen, die bildgestützte Anleitungen bevorzugen, auch im Umgang mit solchen Anleitungen geübt sind. Folglich wird aus den Werten ersichtlich, dass (im Gegensatz zu textuellen und diagrammbasierten Aufgabenannotationen) keine eindeutige Interpretation der bildbasierten Annotationen sichergestellt werden kann. Dies gilt auch für Personen, die Erfahrung im Umgang mit diesem Repräsentationsformat haben. Durch die gleichzeitige Betrachtung der Effektivität wird sichtbar, dass der aufgestellte Interpretationsspielraum keinen negativen Einfluss auf die Aufgabenlösung nimmt. Das bedeutet, dass die Anweisungen nur in Form einer Einschränkung des Lösungsraums interpretiert wurden (z.B. konkrete Position eines Bauteils muss wie im Bild repliziert werden). Der maximale Erfolg der Aufgabenbearbeitung wird allerdings dadurch trotzdem erreicht.

Die Ergebnisse des direkten Modellvergleichs in Abbildung 34b zeigen, dass die Wahl eines bevorzugten Repräsentationsformats für eine Aufgabenannotation von der Aufgabenstellung abhängt. Für die Platzierungsaufgabe schneidet die textbasierte (37%) und bildbasierte (42%) Aufgabenannotation am besten ab. Für die Stapel- und Sortieraufgabe wird die bildgestützte Aufgabenannotation deutlich besser bewertet als die möglichen

Alternativen. Die bildbasierte Version wird von 77% der StudienteilnehmerInnen für die Stapelaufgabe und von 62% für die Sortieraufgabe als Favorit gewählt.

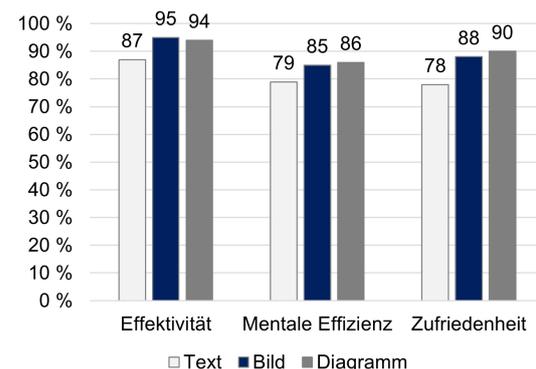
5.3.1.4 BEARBEITUNGSZEIT DER AUFGABEN

Die Zeitmessung der Aufgabenbearbeitung zeigt, dass die ProbandInnen bei der Ausführung des zweiten Prozessmodells durchschnittlich 18 Sekunden schneller waren als bei der ersten Aufgabe. Diese Beobachtung bestätigt die Entscheidung für die Randomisierung der Aufgaben, um aussagekräftige Ergebnisse zu erreichen. Die Betrachtung nach den einzelnen Repräsentationsformaten deckt auf, dass bildgestützte Aufgabenannotationen ($M = 79$ Sekunden) von den TeilnehmerInnen am schnellsten ausgeführt wurden. Anschließend folgen diagrammbasierte Annotationen (81 Sekunden). Am langsamsten wurden Prozessmodelle mit textuellen Aufgabenannotationen ausgeführt ($M = 99$ Sekunden). Die zusätzliche Differenzierung nach der Aufgabenstellung zeigt einen großen Unterschied bei der Bearbeitung der Stapelaufgabe. Für diese brauchten TeilnehmerInnen mit bildgestützten ($M = 79$ Sekunden) und diagrammbasierten ($M = 81$ Sekunden) Annotationen deutlich kürzer als mit der textuellen Version ($M = 126$ Sekunden).

5.3.1.5 ASPEKTE DER INTUITIVITÄT

Die durchschnittlichen Beurteilungen zur Effektivität, mentalen Anstrengung und Zufriedenheit über alle Teilnehmenden zu den verschiedenen Repräsentationsformaten sind in Tabelle 35a zusammengefasst. Dabei sind die unterschiedlichen Skalenniveaus der ver-

		Aspekte der Intuitivität		
		Effektivität $M (SD)$	Mentale Anstrengung $M (SD)$	Zufriedenheit $M (SD)$
Repräsentation	Text	86.8 (15.2)	45.3 (24.5)	3.9 (0.6)
	Bild	95.2 (22.8)	32.4 (36.3)	4.4 (0.9)
	Diagramm	93.6 (13.0)	31.2 (24.0)	4.5 (0.6)



(a) Durchschnittliche Beurteilungen.

(b) Normierte durchschnittliche Beurteilungen.

Abbildung 35: Deskriptive Statistik der drei Aspekte der Intuitivität in Hinblick auf die Repräsentationsformate der Aufgabenannotationen.

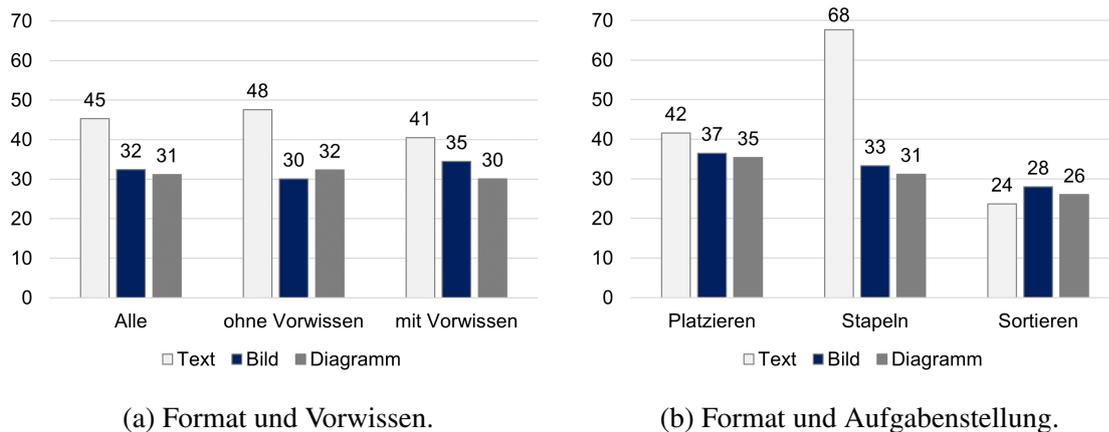


Abbildung 36: Durchschnittliche Beurteilungen zur mentalen Anstrengung unter Berücksichtigung des Repräsentationsformats und weiterer Variablen.

wendeten Messinstrumente zu beachten (Abschnitt 5.2.3.2). Beispielsweise wird die mentale Anstrengung mit einer 220-Punkte-Skala gemessen, bei der hohe Werte einer niedrigeren Anstrengung entsprechen. Entgegen dazu repräsentieren hohe Werte bei der Effektivität eine negative Beurteilung. Zur besseren Vergleichbarkeit werden die Werte in Abbildung 35b normiert und visualisiert. Dadurch sind die Ergebnisse aller Intuitivitäts-Aspekte auf dem selben Wertebereich zwischen 0% und 100% angegeben. Die mentale Anstrengung ist durch die Normierung dann als mentale Effizienz zu betrachten. Der Abbildung ist zu entnehmen, dass alle Repräsentationsformate in allen drei Aspekten grundlegend hohe Werte erzielen. Darunter schneiden textuelle Aufgabenannotationen hinsichtlich aller Aspekte schlechter ab als die anderen Varianten.

Die genauere Betrachtung der Repräsentationsformate gemeinsam mit weiteren Variablen liefert in Hinblick auf die drei Aspekte weitere Ergebnisse. An dieser Stelle werden Grafiken bzgl. der mentalen Anstrengung ausgewählt, da dort die größten Unterschiede in den Bewertungen zu sehen sind. Die Grafiken zu den anderen Intuitivitäts-Aspekten sind gesammelt in den Anhängen C1 und C2 zu finden. Abbildung 36a zeigt die durchschnittlichen Beurteilungen im Vergleich, aufgegliedert nach dem Erfahrungslevel der StudienteilnehmerInnen. So empfinden Personen ohne Vorwissen im Bereich Prozessmodellierung textuelle Aufgabenannotationen (48) anstrengender als Personen mit Vorwissen (41). Für die anderen Repräsentationsformate sind sowohl die Unterschiede als auch die Durchschnittswerte geringer. Die Betrachtung nach den Aufgabenstellungen in Abbildung 36b zeigt, dass die Stapelaufgabe für diesen Wert verantwortlich ist. Die Stapelaufgabe in Textform wird als deutlich anstrengender als die anderen Aufgabenstellungen und Repräsentationsformate beurteilt. Zur weiteren Validierung dieser Ergebnisse erfolgen im nächsten Abschnitt multivariate Analysen.

5.3.2 STATISTISCHE HYPOTHESENPRÜFUNG

Zur Beantwortung der in Abschnitt 5.2.2 aufgestellten Forschungsfragen und Hypothesen werden lineare gemischte Modelle (engl. *linear mixed models*) (LMMs) berechnet [29]. LMMs sind ein gängiges statistisches Verfahren zur Analyse von Beziehungen zwischen abhängigen und unabhängigen Variablen in Datensätzen. Sie eignen sich unter anderem für Untersuchungen im Kontext von wiederholten Messungen und festen Effekten (engl. *fixed effects*). In der experimentellen Studie sind diese Aspekte durch die wiederholte Bearbeitung von Aufgaben und einem unterschiedlichen Erfahrungslevel der StudienteilnehmerInnen gegeben. Die Freiheitsgrade für die Signifikanztestung werden mittels der Satterthwaite-Methode [233] bestimmt. Die Berechnung der Konfidenzintervalle erfolgt standardmäßig unter der Annahme eines Konfidenzniveaus von 95%.

In LMMs werden verschiedene Ebenen verwendet, um die Modellierung von Variation sowohl innerhalb als auch zwischen betrachteten Gruppen zu ermöglichen. Die Ebenen bilden somit die Hierarchie der Datenstruktur ab. Üblicherweise existieren mindestens zwei hierarchische Ebenen [95]. Die höchste Ebene repräsentiert Gruppen (engl. *cluster*), beispielsweise StudienteilnehmerInnen, während die unterste Ebene die individuellen Messungen oder Beobachtungen innerhalb jeder Gruppe darstellt. Zur Auswertung erhielten alle befragten Personen eine eindeutige Personenkennung, die auf Gruppenebene (Level 2) als Clustervariable genutzt wird. Die verschiedenen abhängigen Variablen (Effektivität, mentale Effizienz, Zufriedenheit) werden auf der Beobachtungsebene (Level 1) modelliert. Als Prädiktoren (ebenfalls Level 1) werden für alle Modelle das Repräsentationsformat (Faktor mit 3 Stufen), die Aufgabenstellung (Faktor mit 3 Stufen), das Erfahrungslevel (Faktor mit 2 Stufen) und der Bildungsabschluss (Faktor mit 5 Stufen) einbezogen⁵. Für alle Prädiktoren werden feste Effekte bestimmt. Als Maß der Modellgüte wird das marginale R^2 gemäß [177] verwendet. Dieses beschreibt den Anteil der erklärten Varianz (Gesamtvarianz der abhängigen Variablen durch die unabhängigen Variablen) der festen Effekte im Modell.

Da es sich bei den Prädiktoren um mehrstufige kategoriale Prädiktoren handelt, werden zusätzliche Paarvergleiche durchgeführt. Zur Vermeidung von zufälligen scheinbar signifikanten Unterschieden wird hierbei die Tukey-Methode [135] als gängiges Korrekturverfahren für multiples Testen verwendet.

Die Ergebnisse werden mit dem Statistikprogramm ‚R‘ [222] unter Verwendung der Pakete ‚lme4‘ (für LMMs), ‚lmerTest‘ (für Satterthwaite-Methode), ‚MuMIn‘ (für R^2)

⁵Im Statistikprogramm ‚R‘ beziehen sich die Faktorstufen (engl. *factor levels*) auf die verschiedenen Werte, die ein Faktor bzw. eine Kategorie oder Variable annehmen kann.

Paarvergleich	LMM 1 Effektivität			LMM 2 Mentale Anstrengung			LMM 3 Zufriedenheit		
	E	SE	<i>p</i>	E	SE	<i>p</i>	E	SE	<i>p</i>
B - D	1.60	3.34	0.88	1.26	4.71	0.96	-0.04	0.13	0.94
B - T	8.40	3.34	0.04	-12.84	4.71	0.02	0.49	0.13	0.00
D - T	6.80	3.34	0.11	-14.10	4.71	0.01	0.53	0.13	0.00
<i>p</i> (Basismodell)		0.03			0.01			0.00	
Marginales R^2		0.04			0.05			0.10	

Tabelle 5.5: Ergebnisse der paarweisen Modellvergleiche hinsichtlich der drei Aspekte intuitiver Benutzung, publiziert in [80]: Schätzwerte für den Effekt (E), Standardfehler der Schätzwerte (SE) und Signifikanzniveaus *p*.

und ‚emmeans‘ (für Paarvergleiche und Tukey-Test) und den dort implementierten Versionen der einzelnen Verfahren berechnet.

5.3.2.1 VERIFIZIERUNG VON HYPOTHESE 1A, 1B, 1C

Anhand der LMMs können für alle drei Aspekte der Intuitivität (Effektivität, mentale Effizienz, Zufriedenheit) ein signifikanter Zusammenhang mit den Darstellungsformaten von Aufgabenannotationen festgestellt werden. Tabelle 5.5 ist zu entnehmen, dass in allen drei linearen gemischten Modellen textbasierte Annotationen (T) am schlechtesten abschneiden. Hinsichtlich der Effektivität (LMM 1) können die geringsten Werte für textuelle Annotationen festgestellt werden. Diese sind aufgrund der Unterschreitung eines *p*-Werts von 0.05 signifikant im Vergleich zu bildbasierten Annotationen (B) ($p = 0.04$). Bei der Gegenüberstellung von textuellen zu diagrammbasierten Annotationen (D) liegt keine signifikante Überlegenheit vor ($p = 0.11$). Auch diagramm- und bildbasierte Annotationen unterschieden sich nicht wesentlich voneinander ($p = 0.88$). Ähnliche Beobachtungen können für die mentale Anstrengung (LMM 2) und Zufriedenheit (LMM 3) abgeleitet werden. Textbasierte Annotationen sind bildbasierten Annotationen ($p = 0.02$ und $p = 0.0$) und diagrammbasierten Annotationen ($p = 0.01$ und $p = 0.0$) signifikant unterlegen. Damit gilt für diese Studie **Hypothese 1a** als **bestätigt**, d.h. dass diagrammbasierte Darstellungen von Aufgabenannotationen intuitiv verständlicher sind als textbasierte Darstellungen. Bilder und Diagramme zeigen dagegen keinen bemerkenswerten Unterschied zueinander (LMM 2 mit $p = 0.96$ und LMM 3 mit $p = 0.94$).

Um den Effekt von Erfahrung (im Bereich Prozessmodellierung und -ausführung) auf die drei Aspekte der Intuitivität (Hypothese 1b) sowie den Effekt des Bildungsgrads auf diese Aspekte (Hypothese 1c) zu überprüfen, werden die LMMs jeweils erweitert. Dabei

wird in jedem LMM der zu untersuchende Prädiktor (Erfahrung, Bildungsgrad) und ein Interaktionsterm zwischen diesem Prädiktor und der Aufgabenstellung bzw. dem Repräsentationsformat eingeschlossen. Eine Übersicht der berechneten Werte findet sich in Anhang C3. Es können weder signifikante Haupteffekte noch bedeutsame Interaktionseffekte bzgl. der Erfahrung von StudienteilnehmerInnen festgestellt werden. Folglich muss **Hypothese 1b abgelehnt** werden. Dies bedeutet, dass Vorwissen in der Prozessmodellierung und -ausführung keinen Einfluss auf die intuitive Verständlichkeit von diagrammbasierten Aufgabenannotationen hat.

Für den Bildungsgrad gilt ein ähnliches Ergebnis mit Ausnahme der mentalen Anstrengung (LMM 2). Hier werden signifikante Unterschiede in Bezug auf den Bildungsgrad gefunden, die jedoch nach Korrektur für multiples Testen (Abschnitt 5.3.2) verschwinden. Damit muss auch **Hypothese 1c abgelehnt** werden, d.h. die intuitive Verständlichkeit eines Repräsentationsformats hängt nicht vom Bildungsgrad ab.

5.3.2.2 VERIFIZIERUNG VON HYPOTHESE 2

Zur Überprüfung der Eignung eines Repräsentationsformats für eine bestimmte Aufgabenstellung liefert die Methode des paarweisen Vergleichs der Formate aussagekräftige Ergebnisse. Dafür werden die Formate zunächst hinsichtlich jedes Aspekts der Intuitivität verglichen. Abbildungen zu den Vergleichen sind gesammelt in den Anhängen C4, C5 und C6 zu finden. Hinsichtlich der Effektivität sind keine signifikanten Unterschiede eines bestimmten Repräsentationsformats für die Platzierungs- und Sortieraufgabe festzustellen. Für die Stapelaufgabe zeigt sich jedoch eine signifikante Unterlegenheit von textuellen Annotationen ($M_{T_{stapel\ n}} = 78$) im Vergleich zu den Alternativen ($M_{B_{stapel\ n}} = 100$ und $M_{D_{stapel\ n}} = 98$). Die Mittelwerte für die Platzierungsaufgabe sind am höchsten für die bildliche und diagrammatische Darstellung ($M_{B_{platzieren}}, M_{D_{platzieren}} = 89$). Dagegen waren die ProbandInnen bei der Sortieraufgabe am effektivsten mit der textuellen Annotation ($M_{T_{sortieren}} = 100$).

Die Untersuchung der mentalen Effizienz durch die mentale Anstrengung liefert ähnliche Ergebnisse. Für die Stapelaufgabe kann eine signifikante Unterlegenheit (aufgrund der Skalierung sind hohe Werte negativ zu bewerten) von textuellen Aufgabenannotationen ($M_{T_{stapel\ n}} = 68$) im Vergleich zu anderen Formaten ($M_{B_{stapel\ n}} = 33, M_{D_{stapel\ n}} = 31$) festgestellt werden. Hinsichtlich der anderen Aufgabenstellungen zeigen die Ergebnisse keine signifikanten Unterschiede zwischen den Repräsentationsformaten.

In Bezug auf die Zufriedenheit werden vergleichbare Resultate wie bei den anderen Aspekten analysiert. Abbildung 37 zeigt, dass die textuelle Annotation der Stapelaufgabe den anderen Formaten signifikant unterlegen ist. Um die Ursachen dieser Bewertung zu

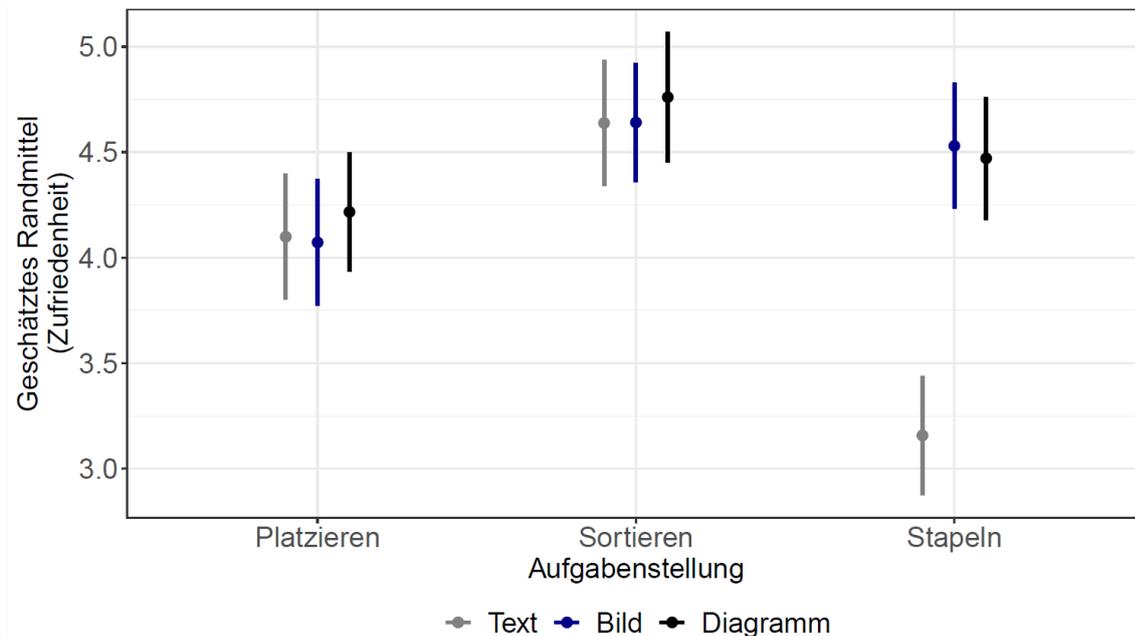


Abbildung 37: Zufriedenheit der StudienteilnehmerInnen unter gleichzeitiger Betrachtung der Aufgabenstellung und des Repräsentationsformats.

klären, werden zusätzliche Untersuchungen zum Zufriedenheitswert bzw. dem QUESI-Score durchgeführt (Anhang C7). Die Betrachtung des Scores nach den fünf Kriterien deckt auf, dass im Vergleich zu den anderen Repräsentationsformaten vor allem die kognitive Beanspruchung und der Lernaufwand deutlich höher sind (Unterschied um mindestens 1.1 Punkte zu einer anderen Darstellung). Bei den anderen beiden Aufgabenstellungen können keine besonderen Zusammenhänge mit einem der Repräsentationsformate festgestellt werden. Insgesamt sind die StudienteilnehmerInnen im Durchschnitt mit der diagrammatischen Annotation bei der Platzierungs- und Sortieraufgabe am zufriedensten ($M_{D_{platzieren}} = 4.2, M_{D_{sortieren}} = 4.7$). Bei der Stapelaufgabe wird die bildbasierte Annotation hinsichtlich des Zufriedenheitsaspekts am besten bewertet ($M_{B_{stapeln}} = 4.6$).

Die gleichzeitige Betrachtung aller Aspekte in Hinblick auf die Aufgabenstellung liefert folgende Ergebnisse. Für die Platzierungs- und Stapelaufgabe können keine signifikanten Unterschiede im Repräsentationsformat festgestellt werden. Dagegen schneidet in der Stapelaufgabe die textuelle Annotation bzgl. aller drei Aspekte der intuitiven Benutzbarkeit signifikant schlechter ab, als die anderen Repräsentationsformate. Somit gilt für diese Studie **Hypothese 2** als **bestätigt**, d.h. abhängig von der Aufgabenstellung sind Aufgabenannotationen in bestimmten Repräsentationsformaten intuitiv verständlicher.

5.3.3 BEANTWORTUNG DER FORSCHUNGSFRAGEN DER STUDIE

Die Ergebnisse der vorherigen Abschnitte ermöglichen eine Beantwortung der beiden im Rahmen der Studie aufgestellten Forschungsfragen (Abschnitt 5.2.2).

FF1 untersucht, ob allgemein ein bestimmtes Repräsentationsformat (Text, Bild oder Diagramm) existiert, mit dem Aufgabenannotation auf eine intuitiv verständliche Weise präsentiert werden können. Dabei bleiben Unterscheidungen hinsichtlich des Erfahrungslevels im Bereich Prozessmodellierung und -ausführung, des Bildungsstands und der Aufgabenstellung unberücksichtigt. Zusammenfassend sind bildgestützte und diagrammatische Aufgabenannotationen am intuitiv verständlichsten. Im Vergleich zu textuellen Annotationen erreichen diese beiden Repräsentationsformate in allen drei Aspekten der Intuitivität (Effektivität, Mentale Effizienz, Zufriedenheit) signifikant höhere Werte. Dabei ist anzumerken, dass absolut betrachtet alle Repräsentationsformate hohe Werte hinsichtlich der drei Intuitivitäts-Aspekte erzielen.

FF2 adressiert mögliche Zusammenhänge bzgl. der intuitiven Verständlichkeit zwischen Repräsentationsformaten von Aufgabenannotationen und den Aufgabenstellungen, für die sie eingesetzt werden. Darunter zielt die Frage insbesondere darauf ab, ob sich für bestimmte Aufgabenstellungen (Platzieren, Stapeln, Sortieren) eines der drei Repräsentationsformate besser eignet als andere. Basierend auf den Ergebnissen zur Überprüfung von Hypothese 2 lässt sich ableiten, dass für Stapelaufgaben textbasierte Annotationen im Vergleich zu bild- oder diagrammbasierten Annotationen weniger geeignet sind. Diese Schlussfolgerung legt nahe, dass sequenzielle Informationen in textuellen Beschreibungen wesentlich komplexer zu interpretieren sind als in alternativen Darstellungsformen. Die auftretenden Abhängigkeiten zwischen den beteiligten Objekten einer Aufgabe erfordern umfangreiche Beschreibungen. Diese müssen gleichzeitig ausgewertet werden und während der Ausführung abrufbar sein. Erneutes Lesen der Prozessmodelle erweist sich als zeitintensiv und geht mit einer kognitiven Belastung einher. StudienteilnehmerInnen befürworten an dieser Stelle die kompakte Darstellungsform von Bildern und Diagrammen. Für Annotationen zu Platzierungs- und Sortieraufgaben und damit vergleichbaren Prozessschritten sind grundsätzlich alle Repräsentationsformate geeignet.

5.3.4 DISKUSSION

Die Betrachtung der Ergebnisse im Vergleich zu bisherigen Arbeiten, an denen sich das Studiendesign orientiert, liefert weitere Forschungserkenntnisse. Im Folgenden werden die wichtigsten Punkte zusammengefasst:

- Die unterschiedlichen Ergebnisse bzgl. der Stapelaufgabe und den anderen Aufgabenstellungen bestätigen die Erkenntnisse in [90], dass bestimmte Repräsentationsformate in Abhängigkeit von der Aufgabenstellung zu präferieren sind. Dieser Aspekt gilt somit sowohl für die Darstellung von Aufgaben, als auch für Aufgabenannotationen.
- Im Gegensatz zu den Ergebnissen in [228] hat das Erfahrungslevel im Bereich Prozessmodellierung und -ausführung der StudienteilnehmerInnen keinen wesentlichen Einfluss auf das intuitive Verständnis eines bestimmten Repräsentationsformats. In [228] erweisen sich diagrammatische Prozessrepräsentationen für Personen mit Erfahrung verständlicher als für Personen ohne Erfahrung. Auch in der hier durchgeführten Studie erzielen erfahrene ProbandInnen im Schnitt bessere Werte für diagrammbasierte Annotationen in allen drei Aspekten der Intuitivität (Anhang C1). Allerdings sind die Unterschiede nicht signifikant, weshalb keine statistisch bedeutsamen Schlussfolgerungen bzgl. des Erfahrungslevels gezogen werden können.
- In der Studie von [279] erreichen AkademikerInnen höhere Punktzahlen für verschiedene Prozessnotationen als Personen ohne universitären Abschluss. Dieses Ergebnis kann aufgrund einer zu kleinen Stichprobe im Rahmen der vorliegenden Studie nicht bestätigt werden. Zwar treten vereinzelt höhere Werte für Personen mit akademischen Hintergrund auf, allerdings sind diese Unterschiede gering und aufgrund der geringen Anzahl an TeilnehmerInnen in den einzelnen Ausbildungsgruppen nicht belastbar.

Die begrenzte Stichprobengröße muss generell bei der Interpretation der Studienergebnisse berücksichtigt und diskutiert werden. Sie schränkt die Belastbarkeit der statistischen Modelle ein. Obwohl anzunehmen ist, dass aufgrund der signifikanten Unterschiede in den Ergebnissen der textuellen Annotationen eine größere Stichprobe diese Ergebnisse noch deutlicher hervorheben würde, sollten zukünftige Studien zu diesem Thema größere Stichproben verwenden. Eine höhere Incentivierung kann für diesen Zweck unterstützend wirken, wie z.B. in [91]. Hierfür müssten entsprechende finanzielle Mittel zur Verfügung gestellt werden. In diesem Kontext ist zu betonen, dass die hier durchgeführte Studie einem innovativen Ansatz folgt, der experimentelle Methoden mit Befragungen vereint, und damit durch zeitliche und wirtschaftliche Ressourcen eingeschränkt ist.

Als weiterer Punkt muss die Übertragbarkeit der Ergebnisse auf reale Arbeitsumgebungen diskutiert werden. Zum einen sind die Ergebnisse in einem kontrollierten experimentellen Aufbau unter Überwachung und Anwesenheit der Studienleiterin erzielt

worden. In realen Prozessumgebungen könnten jedoch bisher unberücksichtigte Variablen, wie beispielsweise spezifische Persönlichkeitsmerkmale der ProzessteilnehmerInnen, motivationale Faktoren oder die Arbeitszufriedenheit, einen Einfluss auf die Präferenz bestimmter Repräsentationsformate von Aufgabenannotationen nehmen. Zum anderen konzentriert sich die vorliegende Studie auf simple Tätigkeiten wie das Platzieren, Stapeln und Sortieren von maximal acht Objekten. Obwohl diese Aufgaben in realen Prozessumgebungen verbreitet sind, können gerade im Kontext der Produktfertigung komplexere Aufgaben mit einer bedeutend größeren Anzahl an Objekten auftreten. Zur erfolgreichen Ausführung derartiger Prozessschritte kann Erfahrung im Bereich Prozessmodellierung und -ausführung einen starken Einfluss auf die intuitive Verständlichkeit von Aufgabenannotationen nehmen. Dieser Aspekt sollte in zukünftigen Studien anhand von Aufgabenstellungen aus konkreten realen Prozessumgebungen mit unterschiedlichen Komplexitätsgraden untersucht werden.

5.4 UMWANDLUNG RELEVANTER DETAILS IN AUFGABEN-ANNOTATIONEN UND INTEGRATION

Die Ergebnisse der vorherigen Abschnitte dieses Kapitels fokussieren die Beantwortung des zweiten Teils von Forschungsfrage 2, d.h. wie relevante Prozessdetails intuitiv verständlich in Prozessmodellen dargestellt werden können (Abschnitt 1.3). In diesem Abschnitt werden dagegen die erste und dritte Teilfrage adressiert. Sie diskutieren, wie analysierte relevante Prozessdetails nachverarbeitet werden müssen, um sie effektiv zu verwenden und wie sie in existierende Prozessmodelle integriert werden können. Dafür werden zunächst Aspekte zur Nachverarbeitung relevanter Details und die darauf basierende Erzeugung einer Aufgabenannotation beschrieben. Anschließend werden Methoden zur technischen Integration von Aufgabenannotationen in Prozessmodelle diskutiert.

5.4.1 NACHVERARBEITUNG UND UMWANDLUNG RELEVANTER PROZESSDETAILS

Der Analyseschritt des Gesamtkonzepts extrahiert relevante Prozessdetails aus prozessbezogenen Daten. Dabei können die Details, abhängig von der verwendeten Analysemethode, in verschiedenen Strukturen bzw. Formaten vorliegen. Der einfachste Ansatz zur Verarbeitung relevanter Prozessdetails aus verschiedenen Formaten ist dabei die manuelle Erzeugung von Aufgabenannotationen durch ProzessexpertInnen. Diese Vorgehensweise kann zeit- und ressourcenintensiv sein, ist aber nicht immer vermeidbar und sollte

möglichst effizient gestaltet werden. Um dieser Problematik entgegenzuwirken wird im Rahmen des Gesamtkonzepts durch das Anstreben eines einheitlichen Formats eine automatisierte Erzeugung von Aufgabenannotationen ermöglicht. Dafür ist der Analyseschritt so konzipiert, dass er relevante Prozessdetails im Sinne einer Regel extrahiert, die durch eine mathematische Implikation beschrieben wird (Abschnitt 3.3.4). Diese kann dann beispielsweise in natürlichsprachliche Texte umgewandelt werden [218, 259]. Diese können anschließend für textuelle Aufgabenannotationen verwendet werden. Die Experimente dieser Arbeit zeigen, dass strukturierte Analysemethoden relevante Details r_{sd} liefern, die direkt im gewünschten Format vorliegen (Abschnitt 4.5.3). Eine Nachverarbeitung bei der Verwendung vergleichbarer Ansätze ist somit nicht notwendig, um automatisiert Aufgabenannotationen zu erzeugen. Im Gegensatz dazu liefert die Anwendung unstrukturierter Datenanalyseansätze Prozessdetails r_{ud} in anderen Formaten (Abschnitt 4.4.3). Der im Rahmen dieses Ansatzes konzipierte Globalisierungsschritt ist gezielt darauf ausgerichtet, aus unstrukturierten Informationen eine Regel abzuleiten, die einer mathematischen Implikation folgt. Diese kann dann ebenfalls durch Anwendung entsprechender Ansätze in Aufgabenannotationen umgewandelt werden. In diesem Kontext ist zu erwähnen, dass auch alternative Formate (nicht in Form einer Regel) dienlich sein können, um auf deren Grundlage Aufgabenannotationen zu erzeugen. Beispielsweise wird in [172] untersucht, wie sich relevante Prozessinformationen, die in tabellarischen Strukturen vorliegen, in intuitiv verständliche textuelle Aufgabenannotationen automatisiert umwandeln lassen.

5.4.2 ERGÄNZUNG VON PROZESSMODELLEN UM AUFGABENANNOTATIONEN

Für die Integration einer Aufgabenannotation in ein existierendes Prozessmodell stehen zwei Möglichkeiten zur Verfügung. Die Aufgabenannotation kann (1) als erweiterndes Element im Sinne eines Kommentars oder Anhang an eine Aufgabe im Modell angefügt werden, ohne die bisherige Beschreibung zu verändern, oder (2) mit der existierenden Aufgabenbeschreibung vereint werden und die bisherige Modellbeschreibung verändern.

Die erste Variante ist für alle Repräsentationsformate geeignet. Zur Umsetzung bietet sich beispielsweise die Verwendung von Multimedia-Annotationen an, wie sie in [282] beschrieben werden. Diese sind im Rahmen einer Erweiterung von BPMN entwickelt worden und ermöglichen das Anhängen von Informationen beliebigen Dateityps an Aufgaben in Prozessmodellen. Sie stehen den ProzessteilnehmerInnen während eines Prozessablaufs zur Verfügung und geben unterstützende Instruktionen zur Ausführung einer Aufgabe. Abbildung 38 illustriert, wie Aufgabenannotationen verschiedener Repräsentationsformate als Multimedia-Annotation gemäß [282] an ein BPMN-Modell angehängt

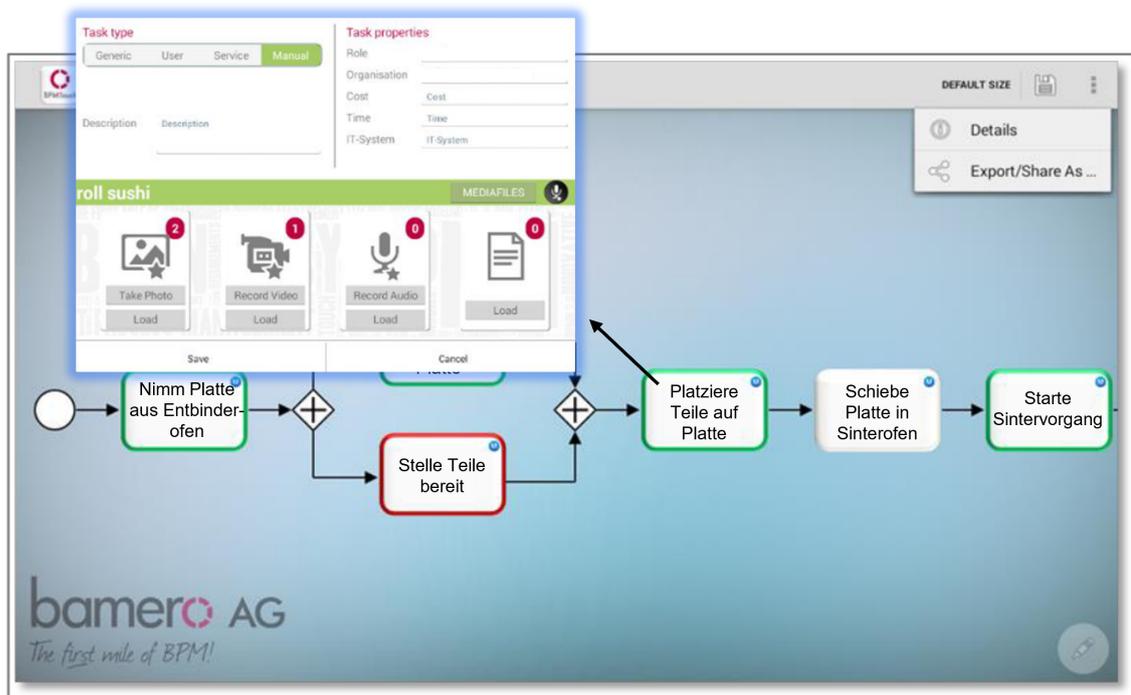


Abbildung 38: Grafische Oberfläche zur Erweiterung von BPMN-Modellen mit Media-Annotationen nach [282] am Beispiel des Sinterprozesses.

werden können. Die Implementierung einer Variante zur automatischen Integration von Multimedia-Annotationen in BPMN-Modelle ist grundsätzlich denkbar.

Der Einsatz der zweiten Variante erfordert eine Unterscheidung abhängig vom Repräsentationsformat einer Aufgabenannotation. Bildgestützte Annotationen können grundsätzlich nicht auf diesem Weg in Prozessmodelle integriert werden. Dagegen können textuelle und diagrammbasierte Aufgabenannotationen wie folgt eingebunden werden.

Um relevante Information textuell zu berücksichtigen, kann der Beschreibungstext einer Aufgabe direkt angepasst werden. Dafür wird die Datei modifiziert, die ein Prozessmodell definiert. BPMN-Modelle basieren z.B. auf XML-Dateien (*eXtensible Markup Language*), die programmatisch angepasst werden können, um die Modellsemantik zu ändern. Abbildung 39 zeigt einen Ausschnitt einer solchen XML-Datei. Dort kann der ‚name‘ eines ‚bpmn:task‘ um die relevante Information textuell erweitert werden. Derartige Anpassungen verändern lediglich die Aufgabenbeschreibungen und behalten die Struktur eines Modells bei, weshalb dieser Vorgang leicht automatisiert werden kann.

Bei diagrammatischen Darstellungen besteht die Möglichkeit, die Struktur des Modells an der Stelle einer betrachteten Aufgabe a zu modifizieren, um Details einzubeziehen. Dies impliziert, dass neue Modellierungselemente hinzugefügt werden, die in Beziehung mit der Aufgabenbeschreibung a stehen, und dass der Kontrollfluss entsprechend angepasst wird. Beispielsweise kann die Aufgabenbeschreibung von a durch die Auf-

```

<?xml version="1.0" encoding="UTF-8"?>
<bpmn:definitions xmlns:bpmn="http://www.omg.org/spec/BPMN/20100524/MODEL"
  <bpmn:collaboration id="Collaboration_0wf0fnz">
    <bpmn:participant id="Participant_0g637ug" name="Prozessteilnehmer" pro
    <bpmn:participant id="Participant_0dnqo0a" name="Prozessteilnehmer&#10
  </bpmn:collaboration>
  <bpmn:process id="Process_1k381sf" isExecutable="true">
    <bpmn:startEvent id="Event_1850z6e">
      <bpmn:outgoing>Flow_1jr5qmn</bpmn:outgoing>
    </bpmn:startEvent>
    <bpmn:task id="Activity_0d5wyas" name="Nimm alle Bauteile aus Kiste">
      <bpmn:incoming>Flow_1jr5qmn</bpmn:incoming>
      <bpmn:outgoing>Flow_19r0ipz</bpmn:outgoing>
    </bpmn:task>
    <bpmn:endEvent id="Event_11fyqzh">
      <bpmn:incoming>Flow_0jzpwjtj</bpmn:incoming>
    </bpmn:endEvent>
    <bpmn:task id="Activity_luluego" name="Lege verbleibende Bauteile zurück">
      <bpmn:incoming>Flow_0q26b85</bpmn:incoming>
      <bpmn:outgoing>Flow_0jzpwjtj</bpmn:outgoing>
    </bpmn:task>
  </bpmn:process>
</bpmn:definitions>

```

Abbildung 39: Ausschnitt einer unter einem BPMN-Diagramm liegenden XML-Datei.

teilung in mehrere Aufgaben a_1, \dots, a_n verfeinert werden. Dabei wird die ursprüngliche Aufgabe a aus dem Modell gelöscht, a_1, \dots, a_n untereinander mit Strukturelementen verknüpft und an der Stelle von a eingefügt. Im Fall von BPMN-Diagrammen kann diese Modifikation beispielsweise programmatisch in der zugrunde liegenden XML-Datei auf dieselbe Weise wie textuelle Änderungen durchgeführt werden. Ein wesentlicher Unterschied besteht allerdings darin, dass sich Anzahl und Hierarchie der Elemente ändern können und die Beziehungen zwischen den Elementen angepasst werden müssen. Bei einer diagrammatischen Integration eines relevanten Details und damit verbundenen größeren Eingriffen in die XML-Datei fällt der Umwandelungsschritt des vorherigen Abschnitts mit dem Integrationsschritt zusammen. Weiter sind für solche Fälle bisher keine geeigneten automatisierten Methoden bekannt. Die relevanten Details müssen zur Bewahrung der Effektivität eines Prozessmodells händisch in die diagrammatische Struktur überführt und geeignet integriert werden.

5.5 ZUSAMMENFASSUNG

In diesem Kapitel wird erläutert, wie der Annotationsschritt aus dem Gesamtkonzept unter Verwendung von Aufgabenannotationen umgesetzt werden kann. Diese enthalten relevante Zusatzinformationen zu Aufgabenbeschreibungen und können unterschiedlich in Prozessmodellen repräsentiert werden. Die damit verbundene Fragestellung nach einem geeigneten Repräsentationsformat wird im Rahmen einer experimentellen Nutzerstudie

beantwortet. Genauer wird evaluiert, welche Repräsentationsformate für Aufgabenannotationen unter Berücksichtigung weiterer Variablen (z.B. Vorwissen oder Ausbildung der ProbandInnen) intuitiv verständlich sind. In der Studie führten Studienteilnehmende Prozessmodelle mit verschiedenen Aufgabenstellungen und Repräsentationsformaten aus und beurteilen Aspekte zur intuitiven Verständlichkeit anhand von Fragebögen. Die im Kontext der Evaluation verwendeten Messinstrumente beruhen auf einer soliden wissenschaftlichen Grundlage, deren Adaption für die Untersuchung der Verständlichkeit von Prozessmodellen einen eigenständigen Beitrag zur methodologischen Diversifikation in diesem Forschungsfeld darstellt. Die Studienergebnisse zeigen, dass grundlegend Bilder, Texte und Diagramme für die Darstellung von Aufgabenannotationen geeignet sind. Dabei sind allerdings diagrammatische und bildliche Aufgabenannotationen im Allgemeinen und unabhängig von der Aufgabenstellung intuitiv verständlicher als textuelle Annotationen. Letztere sollten sich zum einen auf Szenarien beschränken, in denen nicht zu viele Objekte und Abhängigkeiten zwischen den Objekten auftreten. Zum anderen muss bei textuellen Annotationen stark auf Formulierung und Reihenfolge der genannten Teilschritte geachtet werden. Dabei ist zu erwähnen, dass dieser Aspekt gerade für Unternehmen mit international vertretenen Produktionsstätten einen deutlichen Nachteil darstellt. Texte müssen ordnungsgemäß übersetzt werden, was für viele Aufgaben zu einem hohen Arbeitsaufwand führt, der mit erheblichen Kosten verbunden ist [32]. Bei der Verwendung von bildgestützten Annotationen muss in realen Prozessumgebungen darauf geachtet werden, wie genau die zusätzliche Information dargestellt ist. Die TeilnehmerInnen in der Studie neigten häufig dazu, gezeigte Szenen exakt zu reproduzieren und als verpflichtend zu interpretieren. Auch wenn dies keinen Einfluss auf den Prozesserfolg nimmt, beschränkt es den möglichen Lösungsraum erheblich und kann die Ausführungszeit unnötig verlängern. Aus diesem Grund sind abstrakte Darstellungen in Bildern zu bevorzugen. Abschließend wird in diesem Kapitel diskutiert, dass die aus dem Analyseschritt resultierenden Prozessdetails in einem Nachverarbeitungsschritt zunächst in eine einheitliche Struktur transformiert werden sollten. Dies erleichtert nicht nur die anschließende Umwandlung in Aufgabenannotationen, sondern unterstützt auch eine Automatisierung dieses Prozesses. Die vorgestellten Techniken zur Integration von Aufgabenannotationen in Prozessmodelle können abhängig vom gewählten Repräsentationsformat angewendet werden. Darunter können einige auch automatisiert durchgeführt werden, was zur Reduktion des Aufwands in praktischen Anwendungen zu bevorzugen ist.

6 | ÜBERTRAGBARKEIT DES KONZEPTS IN WEITERE DOMÄNEN AM BEISPIEL DER ROBOTIK

Die Problemstellung der vorliegenden Arbeit wird in den vorherigen Kapiteln überwiegend im Kontext der Fertigungsindustrie motiviert. Das entwickelte Gesamtkonzept zeichnet sich allerdings durch hohe Flexibilität aus, die eine Übertragbarkeit auf weitere Domänen ermöglicht. In diesem Kapitel wird am Beispiel der Robotik demonstriert, wie sich das Konzept auch in anderen Bereichen effektiv einsetzen lässt. Dafür werden bestimmte Aspekte und Schritte im Gesamtkonzept herausgehoben, die im Allgemeinen eine Anpassung erfordern, um auch in anderen Domänen entsprechend angewendet werden zu können (Abschnitt 6.1). Im Anschluss erfolgt zunächst eine Einführung in die Robotik, bei der domänenspezifische Anforderungen hinsichtlich Prozessmodellierung und -ausführung durch die Verwendung von Präzedenzgraphen skizziert werden (Abschnitt 6.2). Der Fokus des Kapitels liegt auf den anschließenden Erläuterungen zur Anpassung des Gesamtkonzepts, um auch Präzedenzgraphen durch relevante Prozessdetails verbessern zu können (Abschnitt 6.3). Dabei werden die Anpassungen detailliert erörtert und die Anwendung anhand typischer Szenarien aus der Domäne demonstriert und evaluiert (Abschnitt 6.4). Dem Anwendungsbeispiel in der Robotik folgend werden weitere Domänen und damit verbundene Anpassungen und Herausforderungen an das Gesamtkonzept diskutiert (Abschnitt 6.5).

Ein Großteil der nachfolgenden Inhalte ist bereits in [86] veröffentlicht. Dieses Kapitel erweitert die bestehenden Publikationen, in dem sie in den Gesamtkontext der vorliegenden Arbeit eingeordnet und ausführlicher präsentiert werden. Ergänzend kommen Inhalte in Form von Erläuterungen zur Anpassung des Gesamtkonzepts unter Verwendung von Prozesswissen dazu. Außerdem wird die Anwendbarkeit des Konzepts durch Betrachtung weiterer Bereiche neu beleuchtet.

6.1 DOMÄNEN- UND PROZESSSPEZIFISCHE ANPASSUNGEN DES GESAMTKONZEPTS

Das Gesamtkonzept verfolgt eine möglichst allgemeine Architektur, um in verschiedenen Anwendungsbereichen gewinnbringend genutzt werden zu können. Dabei erfordert seine effektive Implementierung in einer Domäne in erster Linie eine Identifikation derjenigen Aspekte, die tieferes Domänen- und Prozesswissen voraussetzen. Diese Aspekte müssen dem Anwendungsfall entsprechend modifiziert werden. Sie benötigen, abhängig vom Prozess, teilweise mehr oder weniger Kenntnisse über den Anwendungskontext. Die Bestimmung dieser Stellen und die Festlegung, wie umfangreich eine Anpassung erfolgen muss, kann aus der Anwendung des Gesamtkonzepts für spezifische Problemstellungen und Prozesse abgeleitet werden. Dadurch wird erst deutlich, welche Elemente und Schritte Domänen- bzw. Prozesswissen erfordern, um zielführend für den Anwendungsfall implementiert werden zu können. Im Rahmen dieser Arbeit liefern die Ergebnisse der Anwendung des Konzepts auf das spezifische Beispiel des Metallspritzgussprozesses aus der Fertigungsindustrie (Abschnitt 4.3.1) wichtige Erkenntnisse für die Übertragbarkeit auf weitere Domänen. Daraus wird ersichtlich, dass die dreiteilige Struktur des Gesamtkonzepts (vgl. Abbildung 9) unverändert beibehalten werden kann. Die Phasen können nacheinander unabhängig von der betrachteten Domäne durchlaufen werden. Dagegen sind abhängig von der Domäne bzw. dem Anwendungsfall einige Aspekte innerhalb der Phasen zu beachten, auf die im Folgenden näher eingegangen wird.

Die Beobachtungsphase bleibt so wie in Abschnitt 3.2 beschrieben unverändert. Es ist lediglich zu erwähnen, dass sich die Ausführung entsprechend dem gewählten Typ des Prozessmodells ändert. Dabei wird ein Prozessmodelltyp durch seine Notation festgelegt, sodass bei der Ausführung von BPMN-Diagrammen beispielsweise anders vorgegangen werden muss, als bei deklarativen Prozessmodellen. Bisher lag der Fokus der Arbeit auf der manuellen Modellausführung, d.h. auf menschlichen Aktionen. In solchen Fällen ist für eine Ausführung die Lesbarkeit des Modells zu berücksichtigen. Dagegen kann eine Ausführung ebenso systemgestützt (z.B. durch Roboter) erfolgen. Dann muss das Ausführungssystem auf den gewählten Prozessmodelltyp abgestimmt sein. Dies betrifft die Ausführung in der Beobachtungsphase, Validierungsphase und im Schritt ‚Ausführung und Labeling‘ in der Verbesserungsphase. Es wird angenommen, dass vorab in einer Prozessumgebung Ausführungssystem und Modell passend zueinander implementiert und konfiguriert werden. Aus diesem Grund wird die Ausführung nicht im Kontext von vertieftem Prozess- und Domänenwissen betrachtet. Auch der Labeling-Schritt wird nicht explizit berücksichtigt, da der Prozesserfolg grundsätzlich quantitativ ohne zwin-

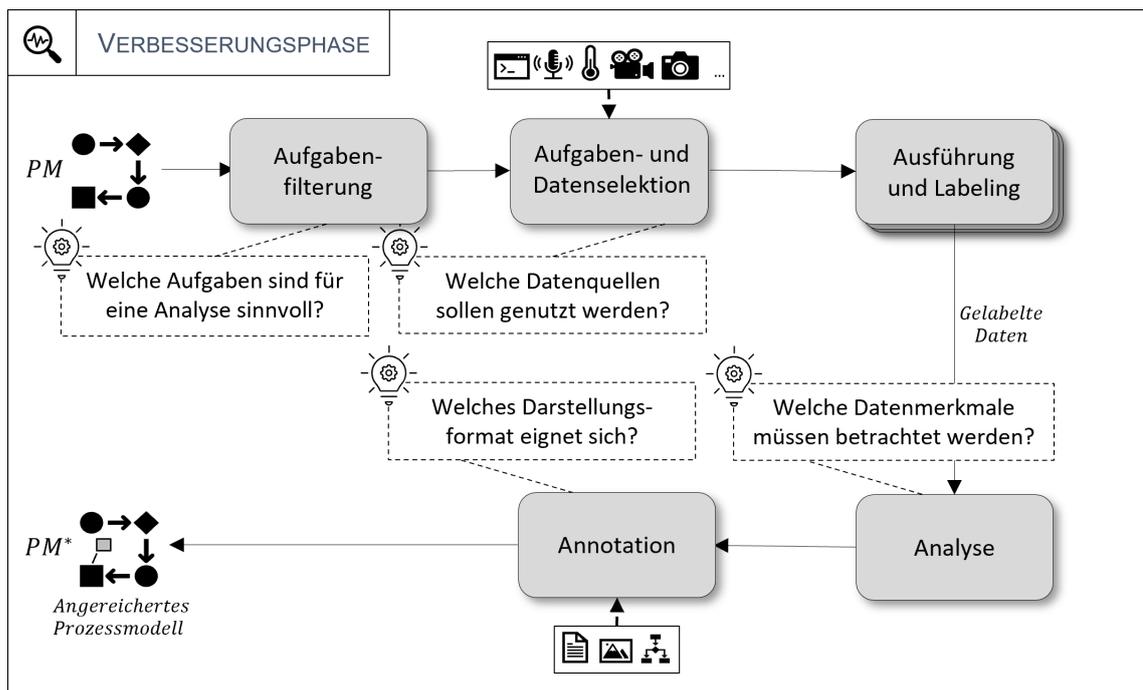


Abbildung 40: Die Anpassung der Verbesserungsphase für eine neue Domäne erfolgt unter Verwendung von Prozesskenntnissen (gestrichelte Rechtecke).

gend Fachwissen einzubeziehen bewertet werden kann. In der Validierungsphase kommt Prozesswissen zur abschließenden Beurteilung der analysierten Prozessdetails zum Einsatz. ExpertInnen entscheiden, ob die vorgeschlagenen Änderungen im Prozessmodell für zukünftige Ausführungen übernommen werden und ob die Verbesserungsphase erneut durchlaufen werden soll. In der Verbesserungsphase selbst wird an mehreren Stellen explizit Domänen- und Prozesswissen benötigt. Abhängig vom Prozesskontext erfordern die Schritte ‚Aufgabenfilterung‘, ‚Aufgaben- und Datenselektion‘, ‚Analyse‘ und ‚Annotation‘ entsprechende Kenntnisse, um effektiv angepasst werden zu können. Abbildung 40 fasst Fragestellungen zu den einzelnen Schritten zusammen, für deren Beantwortung Prozesswissen benötigt wird.

In der **Aufgabenfilterung** wird aus einem Prozessmodell eine Menge an Aufgaben ausgewählt, die grundsätzlich für eine Analyse hinsichtlich relevanter Prozessdetails in Betracht gezogen werden sollen. Dabei sind die Kriterien zur Auswahl domänen- und prozessabhängig und müssen von ExpertInnen bestimmt werden. Eine falsche Auswahl beeinträchtigt den Erfolg aller weiteren Schritte der Verbesserungsphase und damit des gesamten Konzepts. Für viele Anwendungen macht die Filterung bzgl. manuell auszuführender Aufgaben Sinn, da händische Ausführungen potenziell große Unterschiede aufweisen können. Nichtsdestotrotz können, abhängig vom eingesetzten Ausführungssystem, auch andere Kriterien zielführend sein. Beispielsweise liegt in manchen Fällen bereits

schon ein Verdacht vor, welche Aufgaben im Prozess einen Fehler verursachen könnten. An dieser Stelle ist ExpertInnenwissen erforderlich, um die Aufgaben zu identifizieren, die im betrachteten Anwendungsfall eine gute Grundlage für den Analyseschritt liefern.

Im Schritt der **Aufgaben- und Datenselektion** sollte vor allem in der Datenselektion Domänenwissen eingebracht werden. Die Aufgabenselektion ist nach einer sinnvollen Aufgabenfilterung zweitrangig, da eine nicht optimale Selektion höchstens die Anzahl an Durchläufen der Verbesserungsphase erhöht, nicht aber die Effektivität des Konzepts beeinflusst. Dagegen ist die Wahl einer passenden Datenquelle für den Analyseschritt von hoher Bedeutung. Einerseits sollten in diesem Schritt Datenquellen ausgewählt werden, mit denen Daten erfasst werden können, die direkt durch die Ausführung des betrachteten Prozessschritts entstehen. Wenn beispielsweise ein Sinterofen in einem Prozessschritt verwendet wird, ist es empfehlenswert, Temperatur und Betriebszeit aufzuzeichnen. Andererseits obliegt es Prozess- und DomänenexpertInnen zu bestimmen, welche zusätzlichen Datenquellen in Erwägung gezogen werden sollten, um relevante Prozessdetails zu identifizieren. Diese Entscheidung kann unter anderem auf der gezielten Untersuchung konkreter Konfigurationen für Prozessschritte basieren. So kann beispielsweise bestimmt werden, dass die Position von Werkstücken auf einer Platte vor dem Sintern betrachtet werden soll, und dass sich dafür Kamerasysteme besonders eignen.

Die **Analyse** benötigt tiefere Prozesskenntnisse, abhängig von der gewählten Analyse-methode und der Datenquelle (Abschnitt 4.6). Die Effektivität der in dieser Arbeit angewendeten Techniken wird am Beispiel von Bilddaten demonstriert, wobei Kontextwissen an verschiedenen Stellen in die Verfahren einfließt. Im Ansatz mit LIME (Abschnitt 4.4.3) werden Annahmen über den Prozess zur Globalisierung der lokalen Erklärungen getroffen. Der Globalisierungsschritt fasst zwar die analysierte Prozessinformation zusammen, analysiert aber keine neuen Informationen mehr aus den Bildern. Somit lässt sich für diese Methode folgern, dass die Annahmen über den Prozess erst **nach** der Analyse getroffen werden. Diese Annahmen beziehen sich auf Informationen über Objekte in der betrachteten Szene, insbesondere auf Merkmale dieser Objekte, die im Schritt der Bildsegmentierung verwendet werden. Die Objektmerkmale müssen passend gewählt werden, da der Analyseschritt sonst kein sinnvolles Ergebnis liefert. Das Wissen von ExpertInnen beeinflusst an dieser Stelle somit maßgeblich den Erfolg des Gesamtkonzepts. Im Ansatz mit Association Rule Mining (Abschnitt 4.5.3) wird dieses Wissen entgegen dem Ansatz mit LIME sogar bereits **vor** der Analyse genutzt. Dort dient die Bildsegmentierung zur Strukturierung der unstrukturierten Bildinformation. Bei diesem Ansatz stellt die Wahl der Objektmerkmale eine Art Vorbedingung dar und ist damit noch entscheidender, um gewinnbringende Ergebnisse zu erzielen.

Im letzten Schritt der Verbesserungsphase, der **Annotation**, wird Prozesswissen genutzt, um ein geeignetes Repräsentationsformat für die analysierten Prozessdetails zu wählen. Dabei liefern die Ergebnisse der experimentellen Nutzerstudie (Abschnitt 5.3) einen aussagekräftigen Anhaltspunkt, welches Repräsentationsformat für welche Aufgabenstellung geeignet ist. Die abschließende Entscheidung sollte indes stets auf fundiertem Fachwissen von ExpertInnen basieren, da diese in der Lage sind, auch weitere unternehmensweite Faktoren zu berücksichtigen. Beispielsweise könnte in internationalen Betrieben die bildbasierte Annotation zur Überwindung von sprachlichen Barrieren für alle Aufgabenstellungen vorteilhafter sein als alternative Methoden. Außerdem ist in bestimmten Anwendungsfällen das Wissen von ExpertInnen auch für die technische Integration der relevanten Information in das Modell von Bedeutung. Dieser Aspekt adressiert insbesondere Prozessumgebungen, in denen Prozessmodelle nicht manuell, sondern systemgestützt ausgeführt werden (z.B. durch Roboter). In solchen Fällen betrifft die Anpassung eines Modells auch das Ausführungssystem.

In Abschnitt 6.3.1 werden die zuvor erörterten erforderlichen Anpassungen der Verbesserungsphase exemplarisch anhand der Robotikdomäne illustriert und evaluiert. Dabei dient die Robotik grundsätzlich als adäquate Domäne zur Demonstration der Übertragbarkeit des vorliegenden Konzepts, da sie teilweise mit vergleichbaren Herausforderungen wie der Bereich des Prozessmanagements konfrontiert ist. Der demografische Wandel und der Trend zur Kleinserienfertigung von Gütern mit hoher Variabilität stellen neue Anforderungen an die Prozessmodellierung und -ausführung. Insbesondere bei der Verwendung domänenspezifischer Prozessmodelle zur Beschreibung von Abläufen in Produktionsumgebungen ist es erforderlich, zahlreiche spezifische Alternativen zu modellieren. Ziel ist es, dadurch die gesamte Bandbreite der Prozessvarianten abzubilden. Besonders im Kontext von Prozessmodellen, die von Robotern ausgeführt werden sollen, resultiert dieser Aspekt in erheblichem Modellierungs- und Implementierungsaufwand für Designer- und ProgrammiererInnen. Als Lösung sind analog zu Entwicklungen im Bereich des Prozessmanagements [38, 203, 216] Methoden erarbeitet worden, die eine Modellierung von Aufgabenanweisungen auf einem höheren Abstraktionsniveau ermöglichen [60, 195, 226, 243]. Als Folge können auch in der Robotik Prozessmodelle generische Aufgabenanweisungen für Roboter enthalten, in denen relevante Prozessdetails fehlen. Das entwickelte Gesamtkonzept kann nach einer Anpassung auf die Domäne zur Lösung dieser Problematik beitragen. Im weiteren Verlauf des Kapitels wird dieses Vorgehen detailliert erläutert. Weitere Domänen, die von der Anwendung des Gesamtkonzepts profitieren können, werden in Abschnitt 6.5 diskutiert.

6.2 PROZESSMODELLE IN DER ROBOTIKDOMÄNE

Die Anwendung des Gesamtkonzepts in der Robotik erfordert zunächst eine Abstimmung und Abgrenzung der domänenspezifischen Terminologien der beiden Bereiche ‚Robotik‘ und ‚Prozessmanagement‘. Zudem muss ein grundlegendes Verständnis für die Modellierung und Ausführung von Prozessen und Aktivitäten in der Robotik zu entwickelt werden.

6.2.1 TERMINOLOGISCHE ABGRENZUNGEN UND HINTERGRUND

Die Einordnung prozessspezifischer Begriffe der Domänen Robotik und Prozessmanagement zueinander ist in Abbildung 41 veranschaulicht. Für eine klarere Abgrenzung werden die Begriffe in ihrer englischen und somit gebräuchlicheren Bezeichnung belassen und im weiteren Verlauf des Kapitels entsprechend verwendet.

In der Robotikdomäne (Abbildung 41; rechts) beschreiben Aufgaben bzw. **Tasks**, Aktionen, die ein Roboter ausführen soll. Dabei bezieht sich ein Task entweder auf eine einzelne abstrakte Aktivität (z.B. „Montiere das Bedienfeld“) oder auf eine komplexere Aufgabe, einen Prozess, der erledigt werden muss (z.B. „Montageprozess eines Röntgenscanners“). Roboter-Tasks werden in Form von Aufgabenmodellen definiert. Ähnlich wie im Prozessmanagement sind diese aus (roboter-)ausführbaren Bausteinen zusammengesetzt und haben einen eindeutig definierten Einstiegs- und Ausstiegspunkt. Gängige Darstellungsformen von Roboteraufgabenmodellen umfassen **UML/P-Zustandsdiagramme** [268], **Präzedenzgraphen** [183, 224] oder **UND/ODER-Bäume** [60, 184]. Für die Ausführung solcher Modelle durch Roboter müssen sie in sog. **Skills** zerlegt werden, die

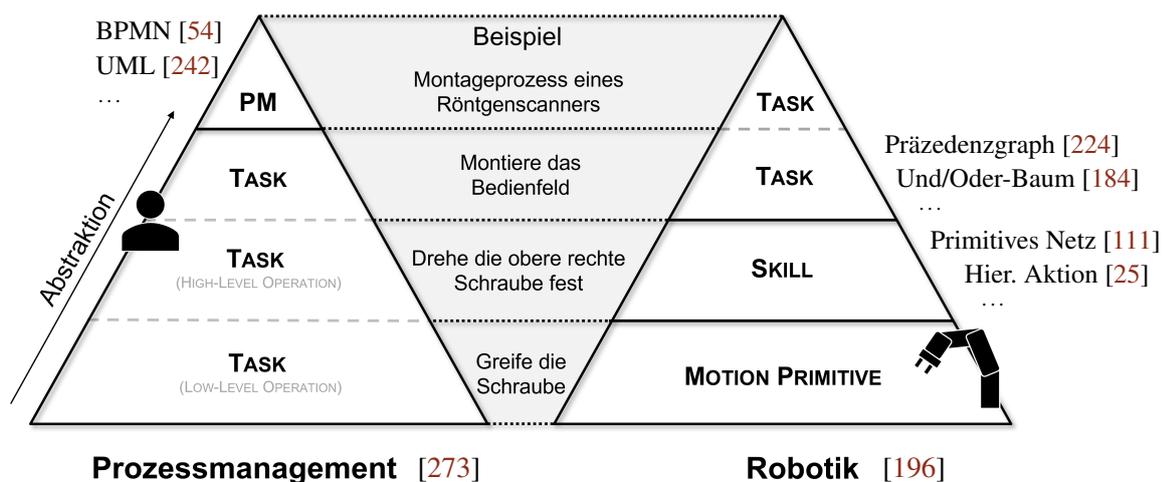


Abbildung 41: Einordnung wichtiger Begriffe zur Modellierung und Ausführung von Aufgaben in die Prozessmanagement- und Robotikdomäne nach [86].

notwendige Operationen zur Ausführung der Aufgabe auf einer niedrigeren Ebene konkretisieren [196]. Zum Beispiel ist die Aufgabe „Drehe die obere rechte Schraube fest“ einer der Skills zur Umsetzung der abstrakteren Aufgabe „Montiere das Bedienfeld“. Skills können in **hierarchische Aktionen** [25] oder **primitive Netzstrukturen** [111] zerlegt werden, die wiederum auf **Bewegungsprimitive** (engl. *motion primitives*) abgebildet werden können. Diese definieren den konkretesten Satz von Operationen, der einem einzelnen Befehl an einen Roboter entspricht. Sie beinhalten die Spezifikation von Punkten in der Umgebung, die der Roboter erreichen muss, sowie Greiferaktionen (z.B. „Greife Schraube“) [111]. Bewegungsprimitive werden wiederum auf Programmcode abgebildet, der als Eingabe für den Roboter zur Ausführung benötigt wird.

Genauso wie in der Robotik werden im Prozessmanagement (Abbildung 41; links) Prozessmodelle (PM) genutzt, um Abläufe (z.B. „Montageprozess eines Röntgenscanner“) zur Erreichung eines bestimmten Ziels darzustellen (Abschnitt 1.1). Sie enthalten eine Reihe von Tasks, die zur Absolvierung eines Prozesses erforderlich sind. In der Robotik kann ein Task ohne Abbildung auf konkretere Ebenen bis hin zu Programmcode vom Roboter nicht ausgeführt werden, was eine Unterteilung zwingend notwendig macht. Dagegen können Aufgabenbeschreibungen von Menschen trotz eines hohen Abstraktionslevels interpretiert und ausgeführt werden. Eine Zerlegung eines Tasks in einzelne Operationen ist nicht notwendig, sodass dessen Detaillierungsgrad im Prozessmanagement von Modellierenden entschieden wird und eher mit Aspekten der Modellverständlichkeit und -vollständigkeit in Beziehung zu bringen ist. Beispielweise kann es abhängig von der Situation effektiver sein, den Prozessschritt „Montiere das Bedienfeld“ als einzelnen Task zu modellieren oder durch mehrere Tasks abzubilden, welche die Tätigkeit auf konkreter Ebene beschreiben. Einer dieser Tasks könnte dann die Anweisung „Drehe die obere rechte Schraube fest“ enthalten oder sogar „Greife Schraube“, falls noch detaillierter modelliert wird. Im Prozessmanagement existieren demnach keine verschiedenen Abstraktionslevels von Tasks. Ein Task entspricht einem elementaren und endgültigen Modellierungselement, das die unterste Abstraktionsebene eines Prozessmodells bildet. Die Granularität eines Prozessmodells wird ausschließlich durch Modellierungsentscheidungen bestimmt. Die linke Seite in Abbildung 41 spiegelt diesen Sachverhalt wider. In dieser Arbeit werden Operationslevel eingeführt, um verschiedene Detaillierungsgrade von Tasks dennoch zu unterscheiden.

Abhängig vom Prozessausführenden kann somit ein Task mehr oder weniger detailliert definiert werden. Menschen wenden bei der Ausführung Kontextwissen und Erfahrung unbewusst an. Dadurch sind sie in der Lage, (i) implizit notwendige Teilschritte eines abstrakten Tasks automatisch auszuführen und (ii) intuitiv die in der Aufgabenbeschreibung genannten Objekten mit denen in der Umgebung verfügbaren Objekten abzuglei-

chen. Im Gegensatz dazu können Roboter diese kognitive Leistung nicht erbringen und benötigen Systemunterstützung. Der zweite Aspekt (ii) wird in der Robotik durch den englischen Fachterminus **Anchoring** [57] beschrieben und befasst sich mit der Zuordnung von fiktiven Objekten zu physischen Objekten, die von den Sensoren eines Roboters erfasst werden. In Abschnitt 6.2.3 wird dieser Aspekt noch einmal genauer erläutert.

Die terminologische Abgrenzung verdeutlicht die unterschiedlichen Anforderungen an Menschen und Roboter, welche bei der Anpassung des Gesamtkonzepts berücksichtigt werden müssen. Um konkrete Aspekte dieser Anpassungen zu veranschaulichen, liegt der Fokus in der vorliegenden Arbeit auf Präzedenzgraphen. Dafür werden Modellierung und Ausführung von Präzedenzgraphen in der Robotik im Folgenden detailliert betrachtet.

6.2.2 MODELLIERUNG VON ROBOTERAUFGABEN MIT PRÄZEDENZGRAPHEN

Wie im vorherigen Abschnitt erläutert, repräsentieren Präzedenzgraphen eine typische Methodik zur Beschreibung und Ausführung von Roboteraufgaben. Dabei kann die Erstellung solcher Präzedenzgraphen sehr aufwändig sein. Enthaltene Aufgabenbeschreibungen müssen alle für den Roboter notwendigen Operationen umfassen oder Techniken implizieren, die Aufgaben entsprechend herunterbrechen. Die Entwicklung von Systemen mit visueller Roboterprogrammierung ist eine gängige Methode, um ProgrammiererInnen die Erstellung von Aufgabenmodellen zu erleichtern [195, 224, 226, 243, 256]. Dabei ist der Ansatz von [226] zur Erstellung von Präzedenzgraphen für diese Arbeit von besonderem Interesse. Neben der Bereitstellung eines Grafikeditors unterstützt der Ansatz die Modellierung abstrakter Aufgabenanweisungen. Dadurch können aufwändige Änderungen eines Modells vermieden werden. Beispielsweise erleichtert der Ansatz die Berücksichtigung von Produktvarianten, indem statt mehreren Prozessen ein abstrakter Prozess modelliert wird. Allerdings führt diese Verallgemeinerung zu einer Informationsreduktion und damit potenziell zum Fehlen relevanter Prozessdetails. Dementsprechend betreffen derartige Modellierungsansätze dieselbe Problemstellung wie in Kapitel 1 dieser Arbeit erläutert und können vom entwickelten Gesamtkonzept stark profitieren. Im Folgenden wird der Ansatz von [226] skizziert. Die formalen Darstellungen folgen den Definitionen in der referenzierten Arbeit.

Physische Objekte im Arbeitsbereich sind durch **Objektzustände** (engl. *part states*) kodiert, während sog. **Objektvorlagen** (engl. *part templates*) teilweise mehrdeutige Anforderungen an Objekte beschreiben. Sowohl Objektzustände als auch -vorlagen weisen dieselben Merkmale je nach Anwendungskontext auf. Im Kontext dieser Arbeit dienen der Typ und die Position eines Objekts als Merkmale. Dabei beschreibt ein **Objekttyp**

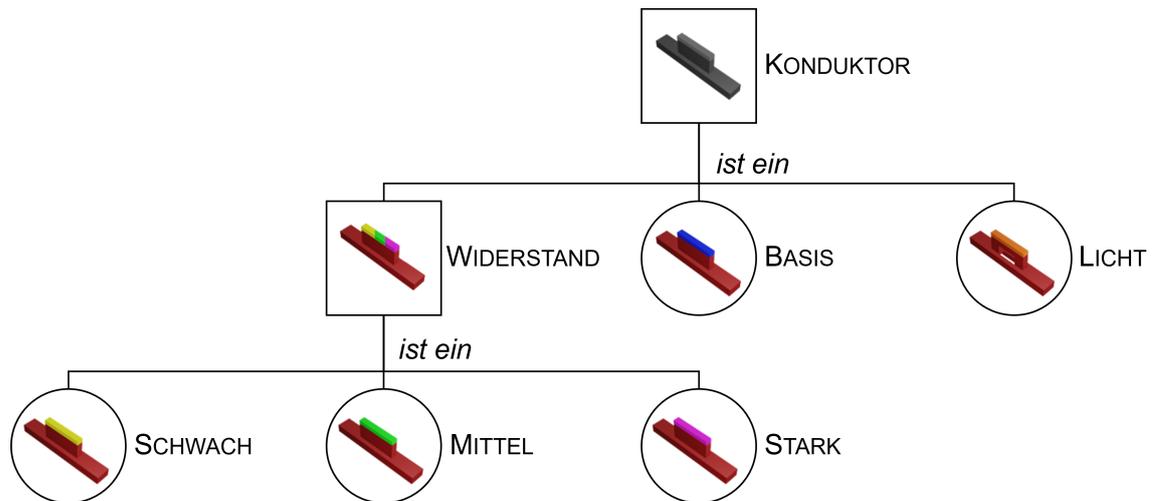


Abbildung 42: Taxonomiebaum mit generischen Objekttypen (eckige Knoten) und spezifischen Objekttypen (runde Knoten) nach [86].

(engl. *part type*) P^{Typ} einen Eintrag in einer baumförmigen Taxonomie mit hierarchischen Beziehungen zwischen den Knoten. Die Blätter des Taxonomiebaums entsprechen wiederum **spezifischen Objekttypen** $\hat{P}^{\text{Typ}} \subset P^{\text{Typ}}$. Jedes physische Objekt wird genau einem dieser spezifischen Objekttypen zugeordnet. Aufsteigend von einem Blatt zum Wurzelknoten kodieren innere Knoten **generische Objekttypen**, also fiktive bzw. abstraktere Typen mit vielfältigen Beschreibungen und Unterkategorien. Abbildung 42 zeigt ein Beispiel eines Taxonomiebaumes. ‚Basis‘(-Konduktor) und ‚Licht‘(-Konduktor) spezifische Typen des generischen Objekttyps ‚Konduktor‘. Formal kann dies durch die Beziehung $\text{IST_EIN}(p_i^{\text{Typ}}, p_j^{\text{Typ}})$ ausgedrückt werden. Damit kann überprüft werden, ob $p_i^{\text{Typ}} = p_j^{\text{Typ}}$ gilt, oder p_i^{Typ} ein transitiver Kindknoten (d.h. eine Unterkategorie) von p_j^{Typ} ist.

Objektlagen (engl. *part locations*) P^{Lage} beschreiben die Lage starrer Objekte im Raum durch ihre Position und Orientierung. Dabei werden zwei Fälle unterschieden:

1. Eine **spezifische Objektlage** $\hat{p}^{\text{Lage}} \in \hat{P}^{\text{Lage}}$ ist eine starre Körpertransformation $wT_{\text{Objekt}} \in \mathbb{R}^{4 \times 4}$, die Translation und Rotation eines Objekts in Bezug auf ein bestimmtes Weltkoordinatensystem w bestimmen (mit $\hat{P}^{\text{Lage}} \subset P^{\text{Lage}}$).
2. Eine mehrdeutige **generische Objektlage** $p^{\text{Lage}} \in P^{\text{Lage}}$ spezifiziert ein 3D-Volumen, in dem ein Objekt erwartet wird. Zum Beispiel sollte sich ein Objekt in einem Bereich auf einem Untergrund, z.B. einem Tisch befinden, der durch eine minimale und maximale Position eines achsenparallel ausgerichteten Rechtecks begrenzt ist.

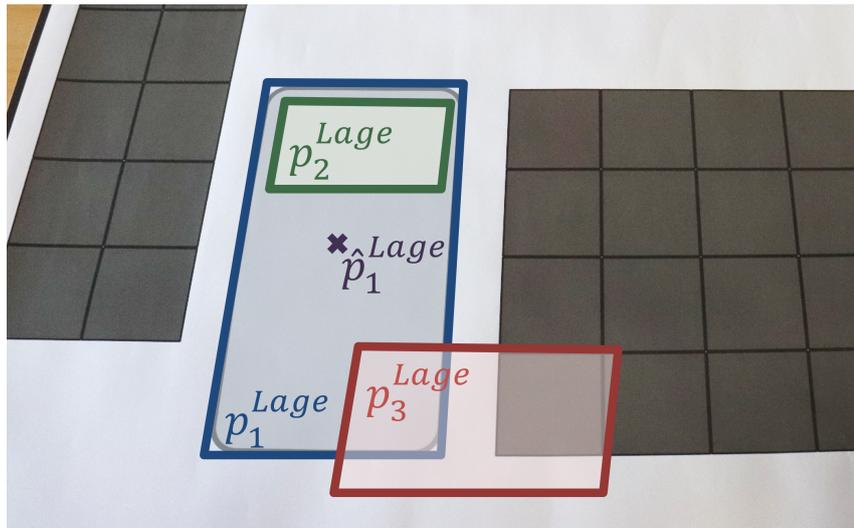


Abbildung 43: Beispiel generischer Objektlagen (p_1^{Lage} , p_2^{Lage} , p_3^{Lage}) oder spezifischer Objektlagen (\hat{p}_1^{Lage}), angelehnt an [86].

Ähnlich zu der Definition für Objekttypen kann die Beziehung $IST_IN(p_i^{Lage}, p_j^{Lage})$ definiert werden, um zu bestimmen, ob p_i^{Lage} Teil des Volumens p_j^{Lage} ist. Die Relation kann zwischen Paaren von Lagen auf verschiedene Arten angewendet werden: spezifisch-spezifisch ($\hat{p}_i^{Lage} \approx \hat{p}_j^{Lage}$), spezifisch-generisch ($\hat{p}_i^{Lage} \in p_j^{Lage}$) und generisch-generisch ($p_i^{Lage} \subseteq p_j^{Lage}$). Zum Beispiel befinden sich in Abbildung 43 die Bereichsbeschreibungen p_2^{Lage} und \hat{p}_1^{Lage} in p_1^{Lage} , wobei p_3^{Lage} keine IST_IN -Beziehung zu irgendeiner der anderen dargestellten Lagen hat.

Der **Weltzustand** (engl. *world state*) wird durch eine Menge $\hat{P} = \{\hat{p}_1, \hat{p}_2, \dots\}$ von Objektzuständen repräsentiert. Jeder Objektzustand $\hat{p}_i = (\hat{p}_i^{Typ}, \hat{p}_i^{Lage})$ ist eine Entität mit einem spezifischen Typ \hat{p}_i^{Typ} und einer spezifischen Lage \hat{p}_i^{Lage} . Dementsprechend enthalten Objektzustände nur wohldefinierte Parameter. Im Gegensatz haben Objektvorlagen $p_i = (p_i^{Typ}, p_i^{Lage})$ einen generischen Typ p_i^{Typ} und eine generische Lage p_i^{Lage} . Sie beschreiben Objekte mit Parametern, die nur teilweise während des Modellierungsschritts bekannt sind. Beispielsweise beschreibt eine Objektvorlage, dass ein Konduktor (ohne Typspezifizierung) an eine beliebige Position innerhalb eines bestimmten Bereichs auf der Arbeitsfläche platziert werden soll. Damit ermöglichen Objektvorlagen die Erstellung von Aufgabenmodellen für Roboter mit einem bestimmten Abstraktionsgrad.

Eine Roboteraufgabe ist ein **Präzedenzgraph** oder Vorranggraph (engl. *precedence graph*) $A = (S, <_S, P)$ bestehend aus teilweise geordneten Skills $S = \{s_1, s_2, \dots\}$ zur Bearbeitung einer Menge von Objektvorlagen P . Die partielle Ordnung $<_S$ beschreibt eine Präzedenzrelation und definiert ‚vorher-nachher‘-Beziehungen zwischen den Skills [183]. Skills repräsentieren beliebige Operationen, um Objektmerkmale zu verändern. Im Kon-

text dieser Arbeit betrifft dies beispielsweise das Überführen eines Objekts in eine neue Lage, d.h. das Platzieren eines Objekts an eine bestimmte Position. Des Weiteren sind Skills als Vorhersagen einer Nachbedingung aus einer Vorbedingung definiert [196]. Dabei werden **generische Skills** als Tupel $s = (p, \psi)$ einer Objektvorlage $p \in P$ und einer Vorhersagefunktion ψ definiert. Die Objektvorlage p repräsentiert dann die Vorbedingungen eines Skills, bezogen auf notwendig vorliegende Objektmerkmale. Durch die Vorhersage ψ werden dann aus p erwartete Objektmerkmale abgeleitet. Somit bildet ψ eine Objektvorlage p (Vorbedingung eines Skills) auf eine weitere Objektvorlage p^* ab (Nachbedingung eines Skills). Dabei ist die Nachbedingung als Einschränkung oder Spezifizierung des Raums der erlaubten Objektmerkmale zu verstehen, wobei diese Einschränkung weiterhin Varianz erlaubt und abstrakt sein kann. Beispielsweise kann durch eine Bewegung eines Objekts generischen Typs seine Lage spezifiziert werden, jedoch bleibt sein Typ weiterhin unterbestimmt. Aufgrund dieses Konzepts lässt sich das Ergebnis eines kompletten Tasks aus deren Skills ableiten. Für eine Menge an Skills S können **vorhergesagte Objektvorlagen** P^* formal wie folgt definiert werden:

$$P^* = \{p^* \mid \forall (p, \psi) \in S: p^* = \psi(p)\} \quad (6.1)$$

Im Vergleich zu anderen etablierten Ansätzen aus dem Forschungsbereich [196], können Skills in der Arbeit von [226] uneindeutige Objekttypen und -lagen enthalten. Um mit diesen Mehrdeutigkeiten umzugehen, müssen die Objektvorlagen zur Laufzeit Objektzuständen, d.h. physischen Objekte im Arbeitsraum zugeordnet werden. Ein Skill $s \in S$ kann dabei nur auf ein physisches Objekt \hat{p}_j angewendet werden, falls \hat{p}_j eine Objektvorlage $p_i \in s$ erfüllt, d.h. falls die Objektmerkmale den Vorbedingungen entspricht, die in der Objektvorlage enthalten sind:

$$\text{ERFÜLLT}(\hat{p}, p) = \text{IST_EIN}(\hat{p}^{\text{Typ}}, p^{\text{Typ}}) \wedge \text{IST_IN}(\hat{p}^{\text{Lage}}, p^{\text{Lage}}) \quad (6.2)$$

Präzedenzgraphen können programmatisch oder systemgestützt erzeugt werden, z.B. mit Hilfe von Grafikeditoren. Abbildung 44 zeigt einen Ausschnitt des Editors von [224, 226]. Dort können Objekte in einer virtuellen Arbeitsumgebung durch Interaktion mit entsprechenden Symbolen platziert werden. Der Editor unterstützt die Festlegung spezifischer als auch generischer Objektlagen. Objekte dienen als Eingabeparameter für Skills, die aus einer Datenbank gewählt werden können. Sie werden durch Kanten zu einem Präzedenzgraph verbunden, wobei die Speicherung eines Modells die automatische Generierung von Vor- und Nachbedingungen bewirkt. Der resultierende Graph wird dann in einer XML-Darstellung kodiert und dient als Eingabe für verschiedene Ausführungsmodule.

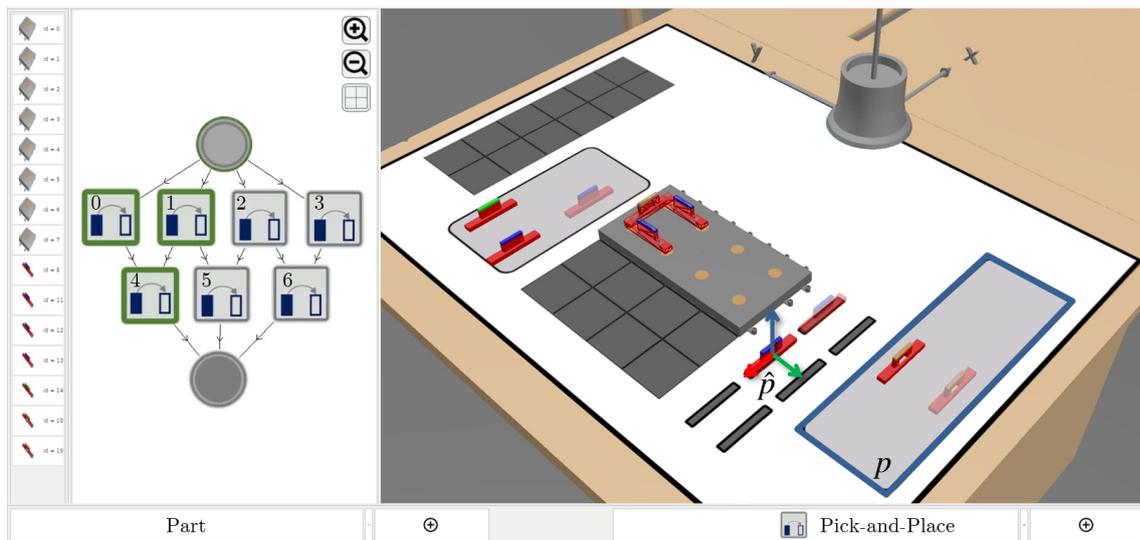


Abbildung 44: Ausschnitt des Grafikeditors von [224, 226] zur Modellierung von Präzedenzgraphen (links) anhand einer virtuellen Arbeitsumgebung (rechts).

6.2.3 AUSFÜHRUNG VON AUFGABENMODELLEN DURCH ROBOTER

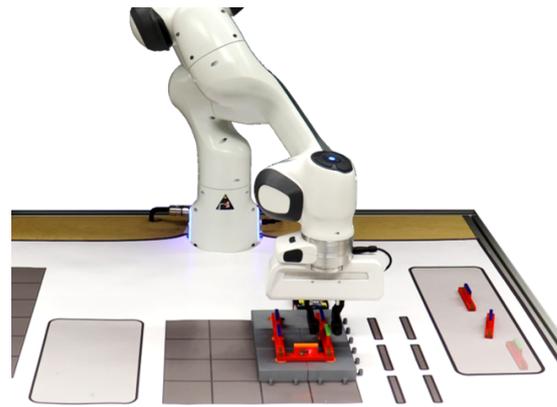
Damit Roboter Aufgabenmodelle wie Präzedenzgraphen ausführen können, muss das Problem der Objektzuordnung gelöst werden, d.h. das Anchoring-Problem. Im Ansatz von [226] erfolgt dies durch eine Erkennung aller Objekte in der realen Arbeitsumgebung durch Objekterkennungsmethoden. Basierend darauf wird wie im vorherigen Abschnitt definiert, ein Weltzustand \hat{P} festgelegt. Durch den Anchoring-Prozess wird jede Objektvorlage $p \in P$ einem Objektzustand $\hat{p} \in \hat{P}$ zugewiesen, der p erfüllt (Gleichung 6.2). Für eine gültige Zuordnung muss mindestens ein Objektzustand pro Objektvorlage bereitgestellt werden ($|\hat{P}| \geq |P|$), wofür $\mathcal{O}(|\hat{P}|!)$ Möglichkeiten existieren¹. Allerdings ist es selbst für wenig Objektzustände ($|\hat{P}| \geq 10$) unpraktikabel, alle Kombinationen von Zuordnungen zu überprüfen. Eine effiziente Herangehensweise ist dagegen die Verwendung des **Kuhn-Munkres-Algorithmus** [175], der das Problem analytisch in $\mathcal{O}(|\hat{P}|^3)$ löst. Dabei sei $M = (m_{i,j})$ eine $|P| \times |\hat{P}|$ Kostenmatrix mit einer Zeile für jede Objektvorlage und einer Spalte für jeden Objektzustand. Jede korrekte Zuordnung von \hat{p}_j zu p_i hat keine Kosten, weshalb der zugehörige Eintrag in der Matrix den Wert 0 enthält. Falsche Zuordnungen haben unendliche Kosten, sodass gilt:

$$m_{i,j} = \begin{cases} 0 & \text{falls ERFÜLLT}(\hat{p}_j, p_i) \\ \infty & \text{sonst} \end{cases}, i \in \{1, \dots, |P|\}, j \in \{1, \dots, |\hat{P}|\} \quad (6.3)$$

¹Die ‚O-Notation‘ (gekennzeichnet durch $\mathcal{O}(\cdot)$) ist eine Methode zur Bestimmung der Laufzeit eines Algorithmus abhängig von seiner Eingabegröße.

M		Objektzustände \hat{P}			
					
Objektvorlagen P		0	0	0	0
		0	0	0	0
		∞	0	∞	∞
		0	∞	∞	∞

(a) Kostenmatrix mit gültigen Zuordnungen von Objektvorlagen zu -zuständen.



(b) Ausführung einer voll spezifizierten Platzierungsaufgabe durch einen Roboter.

Abbildung 45: Lösung des Anchoring-Problems durch eine Kostenmatrix M (links) und Ausführung der Roboterskills (rechts) nach [86].

Abbildung 45a illustriert eine Kostenmatrix für ein einfaches Beispiel hinsichtlich des Objekttyps. Unter den Objektvorlagen ist der generische Objekttyp ‚Konduktor‘ grau und spezifische Objekttypen farbig dargestellt. Die Zuordnungen zu den Objektzuständen innerhalb der ersten beiden Zeilen tragen keine Kosten, da der generische Objekttyp allen Objektzuständen zugeordnet werden kann. Die letztendlich korrekte Zuordnung (grün) durch den Kuhn-Munkres-Algorithmus ergibt sich nach der eindeutigen und korrekten Zuordnung der dritten und vierten Objektvorlage zu den Objektzuständen.

Das Ergebnis des Kuhn-Munkres-Algorithmus lässt sich als eine injektive Abbildung $f: \{1, \dots, |P|\} \rightarrow \{1, \dots, |\hat{P}|\}$ beschreiben, welche die Gesamtkosten $\sum_i a_{i,f(i)}$ ($i \in \{1, \dots, |P|\}$) minimiert. Durch die Konstruktion von M tragen gültige Zuordnungen Kosten von 0 und falsche Zuordnungen unendliche Gesamtkosten. Letzteres tritt genau dann auf, wenn notwendige Objekte im Weltzustand fehlen. Mit f kann eine insgesamt korrekte Zuordnung dann erzielt werden, wenn Objektvorlagen p_i mit dem Objektzustand $\hat{p}_{f(i)}$ assoziiert werden. Nachdem eine gültige Zuordnung gefunden wurde, kann eine Folge von Skills basierend auf der Struktur des Aufgabenmodells geplant werden. Dabei können Aspekte wie die schnellste oder kostenminimale Ausführungsreihenfolge berücksichtigt werden. Darüber hinaus müssen generische Skills aufgelöst werden und auf spezifische Parameter abgebildet werden. Ein vollständig spezifizierter Skill kann dann, so wie in Abbildung 45b beispielhaft gezeigt, von etablierten Robotersystemen [25, 196] ausgeführt werden.

6.3 ERWEITERUNG VON ROBOTERPROZESSMODELLEN UM RELEVANTE DETAILS

Im Folgenden wird demonstriert, wie sich Prozessmodelle für Roboter um relevante Prozessdetails erweitern lassen. Dabei liegt der Fokus auf der damit verbundenen Anpassung der Verbesserungsphase des in dieser Arbeit entwickelten Gesamtkonzepts. Im Übereinstimmung mit den vorangegangenen Abschnitten erfolgt eine Erläuterung des Vorgehens im Kontext von Präzedenzgraphen. Der Ansatz kann jedoch für verschiedene Roboter-aufgabenmodelle verwendet werden. Den Kern der Verbesserungsphase bildet der Analyseschritt zur Extraktion relevanter Prozessdetails aus Prozessdaten. Für diese Domäne wird zur Umsetzung erneut die Methode mit LIME verwendet (Abschnitt 4.4.3), wobei in diesem Kontext zusätzlich Optimierungen betrachtet werden. Die Analysemethode wird anhand typischer Prozesse evaluiert, in denen Roboter zum Einsatz kommen. Dazu werden zwei Szenarien entworfen und synthetische Bilddaten generiert.

6.3.1 ANPASSUNG DER VERBESSERUNGSPHASE

Zur Erweiterung von Roboter-aufgabenmodellen wird die Verbesserungsphase gemäß Abschnitt 6.1 angepasst (vgl. Abbildung 46). Die Eingabe in diese Phase bildet ein bereits existierendes Roboterprozessmodell RPM . Dabei entspricht dieses Modell einem Task für Roboter, der einen gesamten Prozess beschreibt (oberste Ebene in Abbildung 41). Das Roboterprozessmodell enthält somit wiederum eine Menge konkreterer Tasks, die einzelne

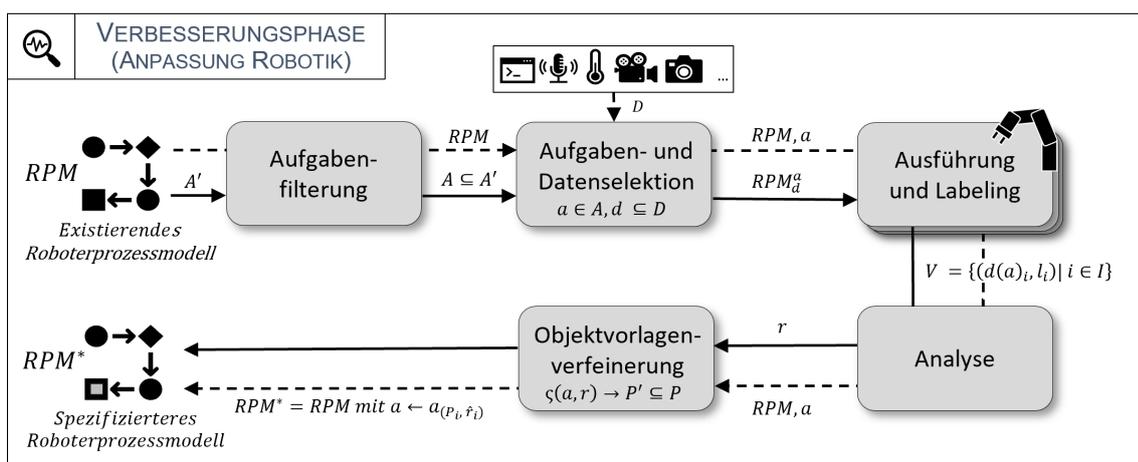


Abbildung 46: Anpassung der Verbesserungsphase zur Erweiterung von Roboterprozessmodellen (RPM) um relevante Prozessdetails.

(aber immer noch abstrakte) Aktivitäten beschreiben. Diese entsprechen Roboteraufgaben A' , welche als Präzedenzgraphen beschrieben werden (Abschnitt 6.2.2).

Anschließend wird A' nach Kriterien von Prozess- und DomänenexpertInnen gefiltert. Diese sind beispielsweise die Anzahl generischer Objektvorlagen innerhalb eines Präzedenzgraphen oder ihr Abstraktionsgrad. Abstrakte Objektvorlagen haben hohes Potenzial für das Fehlen relevanter Prozessdetails, da einzelne Schritte nicht näher spezifiziert sind.

Die nach der Aufgabenfilterung verbleibende Menge von Präzedenzgraphen $A \subseteq A'$ dient als Eingabe für den Aufgaben- und Datenselektionsschritt. In Prozessumgebungen mit Robotern oder direkt am Roboter selbst sind standardmäßig definierte Sensorelemente D integriert, die für die Ausführung oder Überwachung von Arbeitsvorgängen unerlässlich sind. Diese umfassen beispielsweise optische Sensoren zur Orientierung und Objekterkennung sowie Kraft- und Drehmomentsensoren zur Manipulation von Objekten [18, 45]. Die Wahl eines oder mehrerer Sensoren $d \subseteq D$ bietet sich für die Datensammlung im Zusammenhang mit A an. Die Experimente in Abschnitt 6.4 veranschaulichen, dass auch im Kontext der Robotik die Nutzung von Kamerasystemen an dieser Stelle effektiv ist. Alle weiteren Schritte werden unter Annahme von d betrachtet. In der Aufgabenselektion wird ein Präzedenzgraph $a \in A$ zur weiteren Analyse ausgewählt.

Anschließend erfolgt die Ausführung von RPM_d^a durch einen Roboter. Dabei werden Bilddaten gesammelt und in Bezug auf den Prozess Erfolg gelabelt. Wie in Abschnitt 6.1 erläutert sind an dieser Stelle keine weiteren Anpassungen des Schritts erforderlich. Anstelle einer manuellen Ausführung durch Menschen, werden die aus dem Aufgabenmodell ableitbaren Skills automatisiert durch ein Robotersystem ausgeführt.

Für die Analyse der gelabelten Bilddaten V eignet sich die entwickelte Methode mit LIME (Abschnitt 4.4.3) auch für Szenarien aus der Robotik. Für eine effektive Anwendung sind prozessspezifische Kenntnisse über die Objekttypen von Bedeutung. Außerdem ist Wissen über die Anzahl der Objekte, die an der Szene unterstützend. Dieser Aspekt wird zusammen mit einer Evaluation der Methodik in Abschnitt 6.4 erläutert. In typischen Anwendungen in der Robotik repräsentieren ‚Position‘, ‚Farbe‘, ‚Form‘ und ‚Größe‘ angemessene Objektmerkmale für den Globalisierungsschritt [188, 224, 229].

Der anschließende Schritt zur Verfeinerung der Objektvorlagen ersetzt den ursprünglichen Annotationsschritt. In diesem Schritt wird die Regel r genutzt, um a zu spezifizieren. Sie ist das Ergebnis des Analyseschritts und enthält relevante Prozessdetails zu a (Abschnitt 3.3.4). Zur Berücksichtigung der Details müssen zunächst unter allen Objektvorlagen P in a durch die Abbildung $\zeta(a, r) \rightarrow P'$ die Menge der Vorlagen $P' = \{p_1, p_2, \dots\}$ identifiziert werden, die zu den in r enthaltenen relevanten Objektmerkmalen $\hat{R} = \{\hat{r}_1, \hat{r}_2, \dots\}$ passen. Dieser Schritt wird im nächsten Abschnitt detailliert erläutert sowie die Abbildung ζ durch eine konkretere Formalisierung ersetzt. Daran anschließend erfolgt die Um-

programmierung der Objektvorlagen zur Berücksichtigung der relevanten Details. Dies erfolgt im einfachsten Fall manuell durch ProzessexpertInnen und wird in dieser Arbeit nicht näher betrachtet wird.

Das Ergebnis ist ein Roboterprozessmodell RPM^* mit durch relevante Prozessdetails verfeinerten Objektvorlagen. Die damit verbundene Anpassung von a im Vergleich zu der Definition wie im ursprünglichen Modell RPM wird beschrieben durch $a_{(p_i, \hat{r}_i)}$.

6.3.2 VERFEINERUNG DER OBJEKTVORLAGEN

Im Gegensatz zur menschlich interpretierbaren Darstellung relevanter Prozessdetails in Form von Annotationen (Kapitel 5), erfordern Roboter explizite Anpassungen im Aufgabenmodell. Dafür müssen Skills und Objektvorlagen entsprechend der relevanten Information verfeinert werden. Dieses Problem ist verwandt mit der Zuordnung von Objektvorlagen zu Objektzuständen und kann ähnlich formuliert werden. Die nachfolgenden Formalisierungen orientieren sich stark an der zu diesem Kapitel entstandenen Publikation [86]. Die Regel r und Objektvorlagen P stellen generische Merkmale von Objekten dar und können daher ähnlich behandelt werden. Dabei enthält r Informationen zur Ausführung und bestimmt einen erwarteten Weltzustand **nach** der Ausführung. Dagegen legt P Anforderungen an den ursprünglichen Weltzustand **vor** der Ausführung fest. Die Information in r ist somit als Nachbedingung zu verstehen und kann im Prozessmodell durch die Vorhersage von Objektvorlagen (Gleichung 6.1) nach einer Ausführung berücksichtigt werden. Bisher vorhergesagte Objektvorlagen können durch r spezifiziert bzw. verfeinert werden, indem jedes Detail bzgl. eines Objektmerkmals $\hat{r} \in \hat{R}$ zu genau einer vorhergesagten Objektvorlage $p \in P^*$ zugeordnet wird.

Dafür gilt die Annahme, dass relevante Prozessdetails aufgrund der Ausführung von generischen Skills entstehen. Folglich gilt, (i) es gibt gleich viele oder weniger relevante Prozessdetails als Objektvorlagen und (ii) die relevanten Prozessdetails sind spezifischer als die Objektvorlagen. Weiter wird eine Funktion $VERFEINERT: \hat{R} \times P \rightarrow \{\text{TRUE}, \text{FALSE}\}$ definiert mit $VERFEINERT(\hat{r}, p) = \text{TRUE}$ falls ein relevantes Objektmerkmal \hat{r} eine Spezifizierung von p ist, d.h. \hat{r} verfeinert die Objektvorlage p . Dies bedeutet, dass \hat{r}^{Typ} gleich zu oder ein Kind von p^{Typ} ist, und dass \hat{r}^{Lage} gleich zu oder in p^{Lage} liegt. Abhängig von der Implementierung des Analyseschritts kann \hat{R} auch nur Spezifizierungen enthalten, sodass \hat{r}^{Typ} immer ein Kind von p^{Typ} ist, und \hat{r}^{Lage} immer in p^{Lage} liegt (Abschnitt 6.4). Aufgrund der allgemeinen Definitionen zu Objekttypen und -lagen kann die Funktion $VERFEINERT$ analog zu $ERFÜLLT$ (Gleichung 6.2) geschrieben werden als

$$VERFEINERT(\hat{r}, p) = \text{IST_EIN}(\hat{r}^{\text{Typ}}, p^{\text{Typ}}) \wedge \text{IST_IN}(\hat{r}^{\text{Lage}}, p^{\text{Lage}}) \quad (6.4)$$

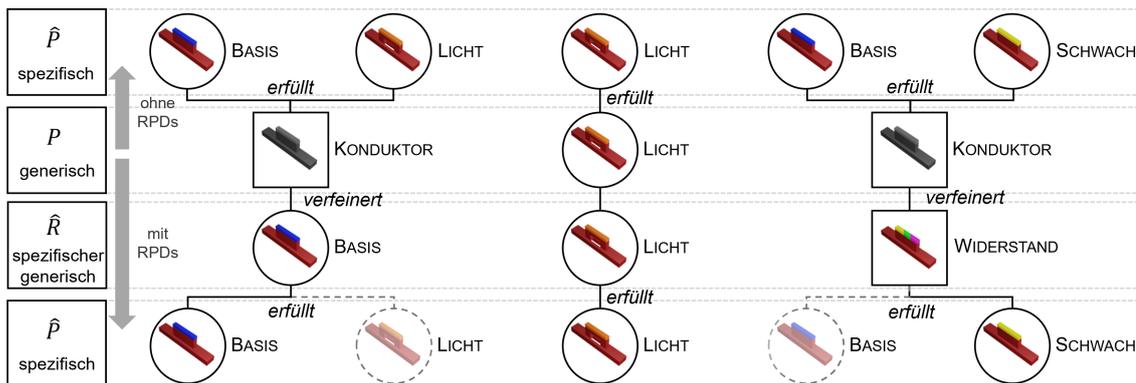


Abbildung 47: Verfeinerung des generischen Typs ‚Konduktor‘ durch den spezifischen Typ ‚Basis‘ und den generischen (aber spezifischeren) Typ ‚Widerstand‘ nach [86].

Abbildung 47 illustriert an einem Beispiel die Verfeinerung von generischen Objektvorlagen hinsichtlich des Objekttyps durch relevante Objektmerkmale \hat{R} . Dabei zeigen die oberen zwei Zeilen der Grafik, welche Zuordnungen ohne Berücksichtigung relevanter Prozessdetails (RPDs) möglich waren. Beispielsweise erfüllen der Basis- und der Lichtleiter (oder der Basisleiter und der schwache Widerstandsleiter) die Spezifizierung des generischen Typs ‚Konduktor‘. Dagegen wird durch Berücksichtigung der relevanten Details der generische Typ ‚Konduktor‘ zu einem spezifischen Typ ‚Basis‘ oder zu einem immer noch generischen aber spezifischeren Typ ‚Widerstand‘ verfeinert (Dritte Zeile). Die unterste Zeile der Abbildung zeigt, dass nach der Verfeinerung nicht mehr alle spezifischen Objekttypen die Vorlagen erfüllen. Während für dieses Minimalbeispiel die Zuordnung nach dem Verfeinerungsschritt eindeutig ist, kann dieser Vorgang sehr komplex werden. Um eine effiziente Zuordnung von \hat{R} nach P^* bzgl. der Funktion VERFEINERT zu finden, kommt auch an dieser Stelle der Kuhn-Munkres-Algorithmus (Abschnitt 6.2.3) zum Einsatz. Dafür sei $M' = (m'_{i,j})$ eine $|\hat{R}| \times |P|$ -Kostenmatrix mit einer Zeile für jedes relevante Objektmerkmal in \hat{R} und einer Spalte für jede Objektvorlage. Falsche Zuordnungen werden mit VERFEINERT modelliert durch

$$m'_{i,j} = \begin{cases} 0 & \text{falls VERFEINERT}(\hat{r}_i, p_j) \\ \infty & \text{sonst} \end{cases}, i \in \{1, \dots, |\hat{R}|\}, j \in \{1, \dots, |P|\} \quad (6.5)$$

Dadurch kann eine Zuordnung $g : 1, \dots, |\hat{R}| \rightarrow 1, \dots, |P|$ mit minimalen Kosten gefunden werden, wobei das relevante Objektmerkmal \hat{r}_i die Objektvorlage $p_{g(i)}$ verfeinert.

Nach der Zuordnung erfolgt die Einschränkung der Objektvorlagen durch die relevanten Objektmerkmale. Eine einfache Übertragung der Werte eines relevanten Merkmals auf die zugeordnete Objektvorlage reicht nicht immer aus, weil die Vorlage bereits durch die

Vorhersage der Aufgabe in Skills transformiert wurde. Dafür muss differenziert werden, ob die ursprünglichen Objektvorlagen und/oder die Vorhersage der Skills angepasst werden müssen. Falls das relevante Objektmerkmal Teil der Nachbedingung ist, d.h. durch einen Skill während der Ausführung verarbeitet wird, muss der Skill so parametrisiert werden, dass die Vorhersage des Skills der angepassten Objektvorlage entspricht. Dies ist beispielsweise bei Spezifizierungen zu Objektpositionen in Platzierungsszenarien der Fall. Ist dagegen das betrachtete Objektmerkmal eine Vorbedingung des Skills, muss die ursprüngliche Objektvorlage angepasst werden. Dies trifft beispielsweise Situationen in denen der Objekttyp eingeschränkt wird, aber der Skill selbst unverändert bleibt.

6.4 EXPERIMENTE, EVALUATION UND ERGEBNISSE

Zur Beurteilung der praktischen Anwendbarkeit des Ansatzes in der Robotikdomäne wurden zwei Experimente durchgeführt. Diese umfassen typische Anwendungsfälle, in denen Leichtbauroboter zum Einsatz kommen. Dabei liegt der Fokus auch in diesen Experimenten auf der Extraktion datenorientierter relevanter Prozessdetails aus Bilddaten unter Verwendung der entwickelten Technik mit LIME. Das Durchlaufen der Verbesserungsphase birgt potenzielle Probleme hinsichtlich der Propagation von Fehlern. Vor allem die Ergebnisse der Analyse sind auch hier entscheidend für den Erfolg des Ansatzes, weshalb dieser Schritt im Mittelpunkt steht. In diesem Kontext werden Optimierungsmöglichkeiten hinsichtlich des Extraktionsprozesses relevanter Information betrachtet. Die Ergebnisse geben Empfehlungen für ähnliche Konfigurationen und weitere Verbesserungsansätze.

6.4.1 SZENARIEN UND AUFBAU

Die zwei entworfenen Anwendungsfälle basieren auf Benchmark-Aufgaben von [225] und den Szenarien aus Abschnitt 4.3.2. Beide Anwendungsfälle behandeln Prozessschritte, bei denen ein Roboter eine Gruppe von Werkstücken (Konduktoren) in einer gegebenen Arbeitsumgebung platzieren muss. Szenario 1 beschreibt eine Bestückungs- und Szenario 2 eine Kittingaufgabe². Abbildung 48 zeigt Aufnahmen der beiden Szenarien.

6.4.1.1 SZENARIO 1: BESTÜCKUNGSAUFGABE

Die Aufgabe im ersten Szenario besteht darin, Konduktoren auf eine Leiterplatte in einer bestimmten Anordnung zu montieren. Sechs Konduktoren müssen platziert werden, wobei jeder durch seine Farbe identifiziert wird. Basisleiter sind blau, Widerstandsleiter

²,Kitting‘ bezeichnet einen typischen Prozess in der Montagelinie, in dem einzelne Teile zu einem Paket (engl. *kit*) zusammengestellt werden.

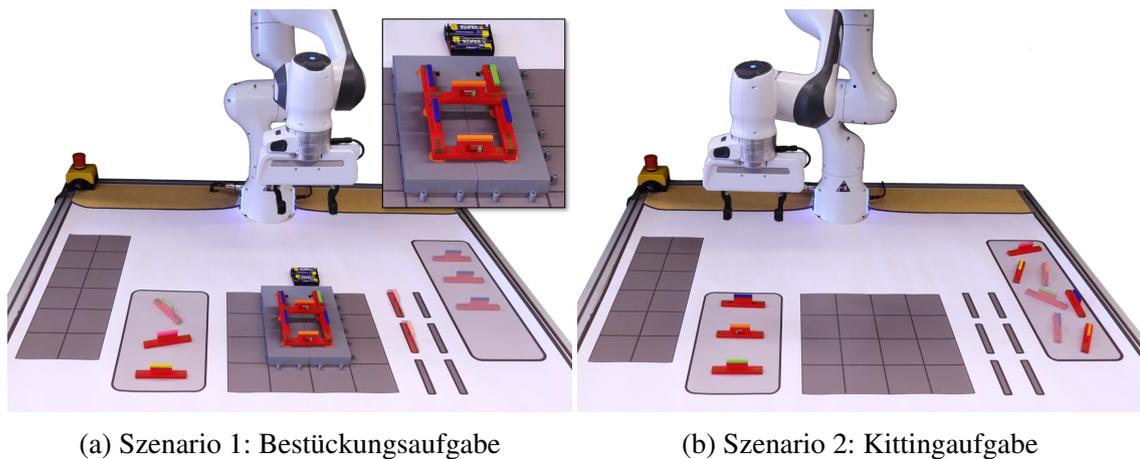


Abbildung 48: Beispiele typischer Anwendungsfälle für Leichtbauroboter [86]. Die halbtransparenten Objekte entsprechen Zuständen vor der Aufgabenbearbeitung.

sind grün, gelb oder pink und Lichtleiter sind orange (vgl. Abbildung 42). Unterschiedliche Farben von Widerstandsleitern geben verschiedene Widerstandswerte an (‚Schwach‘ = Gelb, ‚Mittel‘ = Grün, ‚Stark‘ = Pink). Die Leiterplatte ist in der Szene an einem festen Punkt positioniert. In der Ausgangssituation befinden sich die Konduktoren in den zwei hellgrauen Bereichen in Abbildung 48a. Die genauen Positionen und Orientierungen innerhalb der Bereiche können variieren. In der Praxis werden Aufgabenmodelle häufig von Personen erstellt, die keine tieferen Prozess- und Modellierungkenntnisse besitzen [142, 180]. Dieser Beobachtung folgend wird zur besseren Nachvollziehbarkeit für Szenario 1 angenommen, dass die ModelldesignerInnen zwar mit dem grundlegenden Ablauf des Prozesses vertraut sind, jedoch keine detaillierten Kenntnisse über die Ausführung der einzelnen Schritte besitzen. Folglich enthält das Aufgabenmodell Informationen darüber, dass die Leiterplatte mit drei Basisleitern, zwei Lichtleitern und einem Widerstandsleiter an bestimmten Positionen bestückt werden muss. Es ist jedoch nicht spezifiziert, welcher Widerstandsleiter (mit welcher Stärke) platziert werden soll. Dabei führt das Einsetzen von Leitern mit niedrigem Widerstand (Gelb) zum Durchbrennen des Lichtleiters und zum Fehlschlag des gesamten Prozesses. Ist der Widerstandsleiter zu stark (Pink), leuchtet dagegen der Lichtleiter zu schwach und der Prozess schlägt ebenfalls fehl. Um den Prozess erfolgreich abzuschließen, muss folglich ein Widerstandsleiter mittlerer Stärke (Grün) an der vorgegebenen Position auf der Leiterplatte platziert werden. Da nicht näher im Modell spezifiziert, wählt der Roboter einen Widerstandsleiter eines beliebigen Typs, der während der Aufgabenbearbeitung im Arbeitsbereich verfügbar ist. Aus den folglich beobachtbaren abweichenden Prozessergebnissen werden Labels für die erfassten Bilder nach der Bestückung bestimmt. In diesem Szenario gilt somit das Objektmerkmal ‚Farbe‘ mit der Ausprägung ‚Grün‘ als relevantes Prozessdetail.

6.4.1.2 SZENARIO 2: KITTINGAUFGABE

Der zweite Anwendungsfall beschreibt ein Kittingszenario, also die Bereitstellung aller für die Montage eines Produkts erforderlichen Komponenten. In der Ausgangssituation befinden sich alle verfügbaren Konduktoren in der rechten hellgrauen Region des Arbeitsbereichs (Abbildung 48b). Dabei können in diesem Bereich drei bis maximal sieben Konduktoren verschiedenen Typs zur Verfügung stehen. Im Endzustand müssen genau drei Konduktoren, und zwar ein Basis-, ein Licht- und ein Widerstandsleiter, in der linken hellgrauen Region platziert werden. Diese werden anschließend in einem Montageschritt weiterverwendet um das finale Produkt zusammenzubauen. Aus diesem Grund wird angenommen, dass unter den verfügbaren Konduktoren in der Startregion immer mindestens diese drei Konduktoren zur Verfügung stehen. Dieses Szenario ist angelehnt an typische Problemstellungen im Kontext der Prozessautomatisierung und Industrie 4.0 [100]. Dafür wird angenommen, dass ein Prozessexperte das Aufgabenmodell für den Kittingschritt erstellt hat. Dieses umfasst Aufgabenbeschreibungen für den Roboter zur Platzierung eines Konduktors jedes Typs von der Startregion an beliebige Positionen der Zielregion. Weiter wird angenommen, dass die Aufgabenbeschreibungen generisch modelliert wurden, um Modellierungsaufwand einzusparen. Dieser Detailgrad ist ausreichend, solange der anschließende Montageschritt von menschlichen Arbeitern durchgeführt wird. Diese sind in der Lage mit unterschiedlichen und stark variierenden Positionen der Konduktoren im Zielbereich umzugehen. Auch fehlende Konduktoren können notfalls aus der Startregion entnommen werden. Werden allerdings Schritte im Gesamtprozess automatisiert, sodass der anschließende Montageschritt von einem Roboter ausgeführt wird, müssen die erwarteten Konduktoren an festen Positionen im Zielbereich liegen. Der Basisleiter muss oben platziert werden, der Lichtleiter in der Mitte und der Widerstandsleiter im unteren Drittel der linken Region. Das ursprüngliche Aufgabenmodell ist zu generisch und enthält keine spezifischen Zielpositionen für die Konduktoren. Folglich führt die Ausführung dieses Modells zu der Beobachtung, dass der Prozess gelegentlich fehlschlägt, wobei angenommen wird, dass die Ursache noch nicht bekannt ist. Das relevante Prozessdetail beinhaltet in diesem Szenario somit zwei Objektmerkmale, nämlich ‚Farbe‘ und ‚Position‘ mit den oben beschriebenen Ausprägungen. Dem Aufbau der bisherigen Szenarien aus Abschnitt 4.3.2 folgend werden auch für die Experimente zu dem Bestückungs- und Kittingszenario folgende Annahmen getroffen:

1. Die Aufgabenmodelle für beide Anwendungsfälle liegen bereits in Form von Präzedenzgraphen vor. Die Aufgabenbeschreibungen sind zu generisch gehalten, sodass ihre Ausführung zu abweichenden Prozessergebnissen führt.

2. Wie bereits in den Szenariobeschreibungen angedeutet, sind auch hier die Kriterien für Prozesserverfolg als Referenz für die Validierung des Ansatzes bekannt.
3. Alle Schritte der Verbesserungsphase bis zur Analyse sind bereits ausgeführt worden. Folglich wurden bereits Bilddaten zu den einzelnen Szenarien aufgenommen und entsprechend dem Erfolg der Prozessergebnisse gelabelt.

Im Unterschied zu den Szenarien aus Abschnitt 4.3.2 umfassen die hier betrachteten Anwendungsfälle komplexere Situationen. Neben einer höheren Anzahl an Objekten in den Bildern, steigt auch die Komplexität des Hintergrunds. Außerdem können Objekte verschiedene Orientierungen annehmen.

6.4.2 IMPLEMENTIERUNG UND PROZESSSPEZIFISCHE ANNAHMEN

Für die Experimente werden synthetisch generierte Bilddaten verwendet, um über ausreichend und qualitativ angemessene Daten zu verfügen. Die Bilddaten entsprechen den Szenen aus Abbildung 48 und sind bzgl. der vordefinierten Kriterien für erfolgreiche Prozessausführungen gelabelt.

Im Rahmen von Szenario 1 werden insgesamt 1000 Bilder generiert. Sie umfassen 334 Positivbeispiele, die mit Prozesserverfolg und 666 Negativbeispiele, die mit Prozessfehlschlag assoziiert sind. Die Verteilung der Daten ergibt sich aus den drei verschiedenen Widerstandsstärken, die der relevante Konduktor annehmen kann, wobei auf eine möglichst gleichmäßige Verteilung geachtet wird. Abbildung 49 zeigt Beispiele verschiedener gelabelter Konstellationen des Arbeitsbereichs aus einer Sicht von oben. Dabei zeigen die Bilder den Zustand des Arbeitsbereichs nach der Aufgabenbearbeitung von Szenario 1. Der hellblaue Punkt symbolisiert die Position des Roboters in der Szene. Die Positionen der sechs Konduktoren auf der Leiterplatte sind in allen Bildern identisch, da sie im

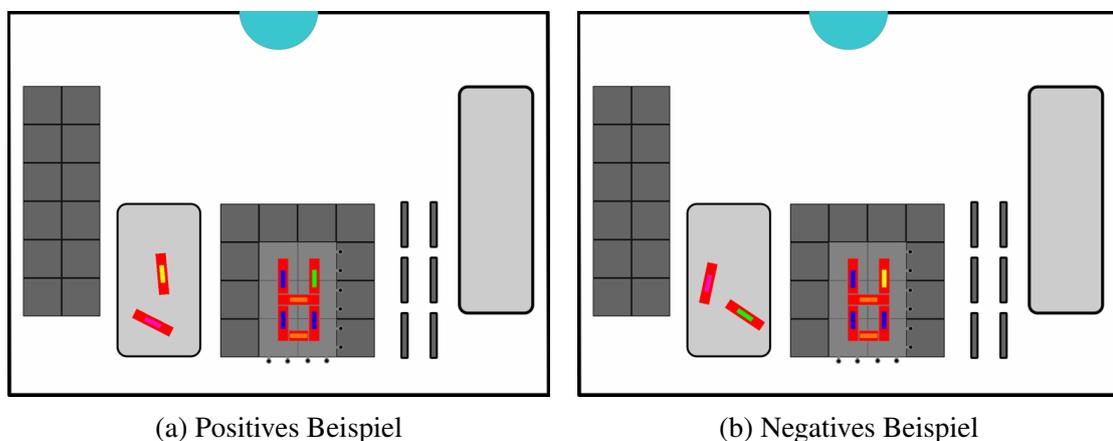
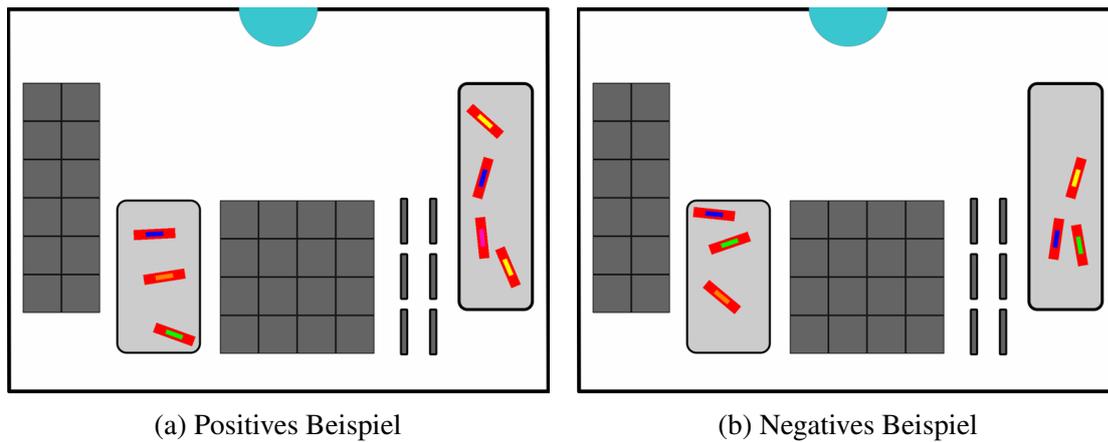


Abbildung 49: Beispiele generierter Bilder für Szenario 1 [86].



(a) Positives Beispiel

(b) Negatives Beispiel

Abbildung 50: Beispiele generierter Bilder für Szenario 2 [86].

Aufgabenmodell konkret definiert sind. Dagegen werden Position und Orientierung der beiden verbleibenden Konduktoren zufällig bestimmt, wodurch abweichende Prozessausführungen simuliert werden. Für Szenario 2 werden 10.000 Bilder generiert, die sich aus 5000 positiv gelabelten und 5000 negativen gelabelten Beispielen zusammensetzen (vgl. Abbildung 50). Die Position und Ausrichtung jedes Konduktors wird zufällig innerhalb der jeweiligen rechteckigen, grauen Bereiche bestimmt. Die deutlich höhere Anzahl an Daten im Vergleich zu Szenario 1 hängt mit dem Analyseschritt zusammen und wird im nächsten Abschnitt näher erläutert. Die Experimente zu diesen Szenarien folgen den Experimenten aus Abschnitt 4.4.4. Das CNN sowie Trainingsdauer und -parameter werden ebenfalls übernommen. Auch LIME wird unverändert mit seiner Standardkonfiguration verwendet, wobei die Parameter n_{features} und n_{samples} wie folgt gewählt werden:

- Ein passender Wert für n_{features} wird gemäß der Prozessdomäne und des experimentellen Setups bestimmt. In den entwickelten Szenarien hängt der Prozesserfolg immer mit den Konduktoren zusammen, wogegen Aspekte wie der Bildhintergrund bei der Aufgabenbearbeitung unverändert bleibt und keinen Einfluss nimmt. Die Anzahl der Objekte in einer Szene ist daher eine gute Richtlinie für die Bestimmung eines passenden Wertes für n_{features} . Da vor der Analyse noch unbekannt ist, welches Objekt oder welches Objektmerkmal relevant ist, müssen alle möglichen auftretenden Objekte berücksichtigt werden. In Szenario 1 können maximal 8 und in Szenario 2 maximal 7 Konduktoren auftreten, weshalb n_{features} entsprechend dieser Werte festgelegt wird.
- Der Parameter n_{samples} zur Bestimmung der Anzahl der Beispielinstanzen bleibt unverändert zu den vorherigen Experimenten und wird auf 1000 festgelegt. Für diesen gibt es keine prozessspezifischen Anhaltspunkte, die man aus den Szenarien ableiten könnte.

Im Globalisierungsschritt wird erneut die Pixelfarbe zur Segmentierung und Objekterkennung genutzt. Die Ergebnisse der Experimente mit den gerade genannten Konfigurationen werden in einem zweiten Experimentendurchlauf optimiert. Die Optimierungen werden detailliert zusammen mit den Ergebnissen in Abschnitt 6.4.3.2 erläutert. Die Implementierungen zu den Experimenten sind im GitHub-Repository zu finden³.

6.4.3 ERGEBNISSE

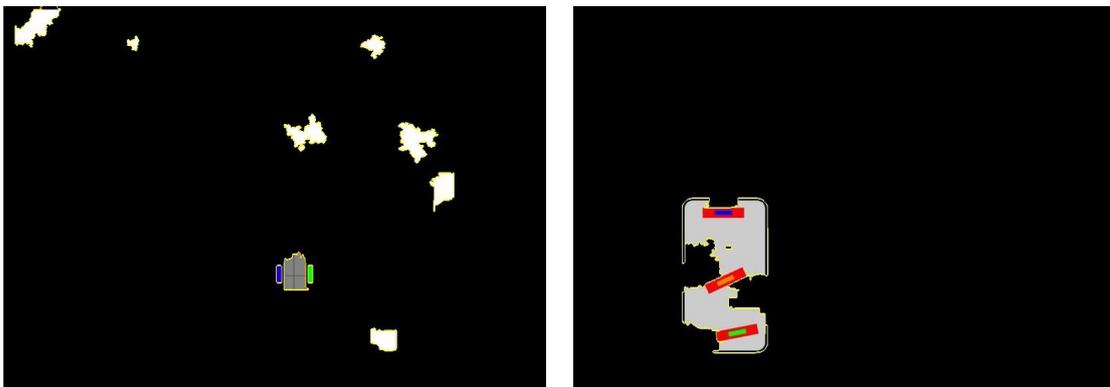
Zur Beurteilung der Experimente werden zunächst die Ergebnisse durch Anwendung von LIME und die Weiterverarbeitung im Kontext des Globalisierungsschritts betrachtet. Diese werden anschließend verwendet, um den Antezedent von Regel r zu konstruieren, wobei bereits zu diesem Zeitpunkt eine Einschätzung des Erfolgs der Analyse möglich ist.

6.4.3.1 ERGEBNISSE MIT DER STANDARDKONFIGURATION VON LIME

Abbildung 51 zeigt Beispiele lokaler Erklärungen zu beiden Szenarien durch die Anwendung von LIME mit der Standardkonfiguration aus Abschnitt 6.4.2. Die Ergebnisse zu Szenario 1 ähneln vorwiegend der Szene in Abbildung 51a. Ein Basisleiter (blaues Rechteck) an der xy -Position (390, 382) und ein Widerstandsleiter mit mittlerer Stärke (grünes Rechteck) an der Position (434, 382) sind hervorgehoben⁴. Daneben sind Superpixel, die nur Hintergrund enthalten sichtbar. Sie werden allerdings aufgrund ihrer Farbe aussortiert und somit bei der Auswertung ignoriert. Dieser Aspekt unterstützt zwar die Reduktion

³https://github.com/MyFi-UBT/thesis_implementation, zuletzt besucht: 01.03.2024.

⁴In der Implementierung werden die Bilder um 90 Grad rotiert verarbeitet, weshalb sich die angegebenen xy -Positionen auf diese Orientierung beziehen.



(a) Beispiel zu Szenario 1 mit $n_{\text{features}} = 8$.

(b) Beispiel zu Szenario 2 mit $n_{\text{features}} = 7$.

Abbildung 51: Beispiele lokaler Erklärungen beider Szenarien in der Standardkonfiguration von LIME in Anlehnung an [86].

unwichtiger Merkmale in dem Szenario, dennoch werden die beiden sichtbaren Konduktoren im anschließenden Globalisierungsschritt als relevante Objekte bewertet. Diese Zuordnung entspricht nicht dem erwarteten Ergebnis, da das konstruierte relevante Detail für Szenario 1 nur den Konduktor mittleren Widerstands einschließt. Darüber hinaus sind in 18,5% aller lokalen Erklärungen weitere Konduktoren hervorgehoben, die das Ergebnis noch stärker von der Erwartung abweichen lassen. Tabelle 6.1 fasst die Ergebnisse nach Durchführung des Aggregationsschritts der Globalisierung zusammen. Dabei sind zeilenweise die Positionen verschiedener Konduktoren in den lokalen Erklärungen vermerkt. Treten Konduktoren bestimmten Typs selten auf ($< 3\%$), werden sie im Sinne von Ausreißern behandelt und erhalten keinen Eintrag in der Tabelle, werden aber mit dem Symbol * markiert. Der Basisleiter und der Widerstandsleiter mittlerer Stärke an den oben genannten Positionen sind in 100% aller lokalen Erklärungen sichtbar. Dabei werden die beiden Konduktoren immer gemeinsam einem einzigen Superpixel zugeordnet, welches hervorgehoben wird. In einigen Erklärungen zu Szenario 1 sind außerdem ein schwacher Widerstandsleiter (6,9%), ein starker Widerstandsleiter (10,2%) und weitere Basisleiter (1,2%) hervorgehoben. Die Widerstandsleiter treten dabei in einem bestimmten Teilbereich der Startregion auf, die in der Tabelle durch Angabe der Minimal- und Maximalwerte rechteckig abgesteckt ist. In einem einzigen Fall ist außerdem der Lichtleiter auf der Leiterplatte an Position (410,463) sichtbar. Unter Einbezug aller häufig auftretenden Konduktoren, umfasst folglich das relevante Prozessdetail vier Konduktoren: einen Basis- und einen Widerstandsleiter mittlerer Stärke an jeweils festen Positionen und einen schwachen und starken Widerstandsleiter in einer bestimmten Positionsregion.

Für Szenario 2 werden 1233 lokale Erklärungen ausgewertet. Der Großteil der bildgestützten lokalen Erklärungen ähnelt Abbildung 51b. Drei Konduktoren (Basis, Licht und mittlerer Widerstand) sind zusammen mit Superpixeln hervorgehoben, die den Hin-

	Szenario 1	Szenario 2
<i>Konduktortyp</i>	<i>Position</i>	<i>Position</i>
Basis	(390, 382) *	[(172, 290),..., (258, 341)]
Schwacher Widerstand	[(179, 316),..., (247, 471)]	*
Mittlerer Widerstand	(434, 382)	[(176, 429),..., (258, 480)]
Starker Widerstand	[(179, 302),..., (258, 458)]	*
Licht	*	[(171, 359),..., (259, 409)]

Tabelle 6.1: Ergebnisse des Globalisierungsschritts beider Szenarien basierend auf den Ergebnissen von LIME mit der Standardkonfiguration (Ausreißer (*) mit einer Häufigkeit von weniger als 3% werden entfernt), angelehnt an [86].

tergrund zeigen. Hier liefert LIME mit der Standardkonfiguration deutlich bessere Ergebnisse als für das erste Szenario. Die Ergebnisse nach dem Aggregationsschritt (vgl. rechte Spalte in Tabelle 6.1) stimmen mit den erwarteten Prozessdetails überein. Für jeden der erwarteten Konduktoren wird der korrekte Bereich innerhalb der Zielregion extrahiert. Auch hier werden die analysierten Bereiche durch Rechtecke beschrieben, die sich auf den oberen, mittleren und unteren Drittel des Zielbereichs beziehen. Lediglich in 2,1 % aller Bilder sind weitere Konduktoren in der Ausgangsregion hervorgehoben.

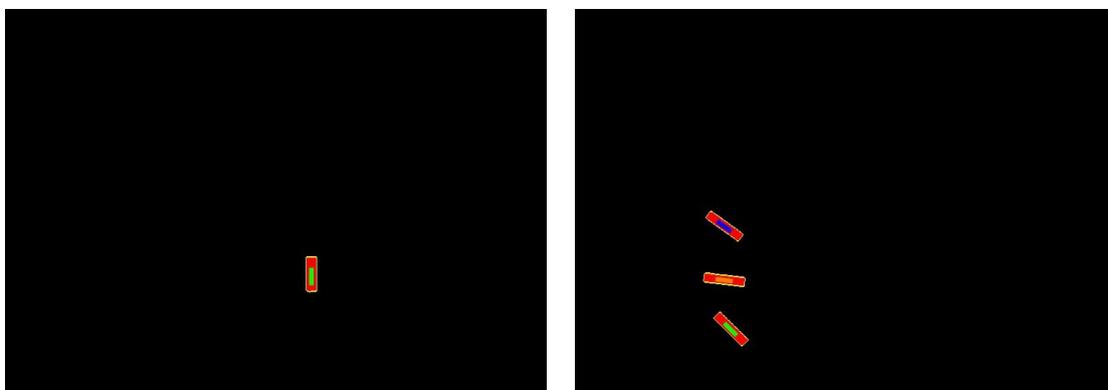
6.4.3.2 OPTIMIERUNG DER ERGEBNISSE

Für Szenario 1 ist eine Optimierung des Analyseschritts erforderlich, um das Ergebnis auf das entscheidende relevante Prozessdetail zu reduzieren. Die Wahl eines höheren Schwellwerts zur Filterung von Ausreißern, d.h. der seltener auftretenden Konduktoren im Aggregationsschritt, ist grundsätzlich möglich. Jedoch muss der Wert abhängig vom Szenario dynamisch festgelegt werden. Dabei besteht die Gefahr, dass seltener auftretende aber dennoch relevante Details verloren gehen. Ein robusterer Ansatz besteht hingegen darin, das bereits vorhandene Prozess- und Domänenwissen zu integrieren. Des Weiteren spielt, wie die Experimente in Abschnitt 4.4.5 zeigen, die Parametrierung von LIME eine signifikante Rolle. Dieser Aspekt bedarf einer eingehenden Untersuchung sowie die Entwicklung von Empfehlungen zur Adressierung ähnlicher Szenarien. Zur Optimierung der Ergebnisse sind folgende Anpassungen zielführend:

1. Der implizite Segmentierungsprozess von LIME muss bzgl. zwei Aspekten angepasst werden. Zum einen muss sichergestellt werden, dass jedes Objekt in einem Eingabebild als einzelnes Segment und somit als einzelner Superpixel betrachtet wird. Unter Einbezug von Wissen über die Form der Konduktoren verhindert dies die Zuordnung des Basis- und Widerstandleiters zu einem gemeinsamen Superpixel in Szenario 1. Daneben wird der standardmäßig in der LIME-Implementierung verwendete **Quick Shift**-Algorithmus [274] mit dem **SLIC**-Algorithmus [12] ausgetauscht. Dieser ist besser auf die Form der Konduktoren angepasst und ermöglicht eine effektivere Segmentierung für die vorliegenden Szenarien.
2. Auf Basis der verbesserten Segmentierung, die jedem Konduktor ein individuelles Segment zuordnet, kann der optimale Wert für den LIME-Parameter $n_{features}$ bestimmt werden ($n_{features} = 1$ für Szenario 1, $n_{features} = 3$ für Szenario 2). Jedes Segment erhält innerhalb der Implementierung von LIME einen Wert, der seine Relevanz für eine bestimmte Klassifikation angibt. Abhängig von der Parameterwahl für $n_{features}$ werden die n Segmente mit den höchsten Werten in der lokalen Erklärung visualisiert. Eine

Sortierung nach der Größe dieses Wertes ermöglicht auch die Bestimmung einer Grenze. Falls der Abstand zwischen zwei aufeinander folgenden Werten einen bestimmten Schwellwert übersteigt, wird $n_{features}$ auf die Anzahl betrachteter Segmente bis zu diesem Punkt gesetzt.

Die Optimierungen führen dazu, dass tendenziell weniger Superpixel hervorgehoben werden. Damit werden Anforderungen an die Robustheit des Analyseschritts verringert. Abbildung 52 zeigt Beispiele lokaler Erklärungen unter Berücksichtigung der Optimierungen. Für Szenario 1 können durch diese Anpassungen signifikant bessere Ergebnisse erzielt werden. Alle generierten lokalen Erklärungen entsprechen Abbildung 52a. Auch für Szenario 2 können perfekte Ergebnisse erreicht werden. Die Optimierung ist für dieses Szenario von weniger großer Bedeutung, da die Ergebnisse mit der Standardkonfiguration bereits akzeptabel sind. Trotzdem sind die lokalen Erklärungen nun präziser und somit zuverlässiger. In diesem Kontext ist zu diskutieren, ob die hohe Anzahl an Eingabedaten in Szenario 2 im Vergleich zum ersten Szenario unerlässlich für das Erzielen der Ergebnisse ist. Eine unzureichende Stichprobengröße oder eine unausgewogene Verteilung von positiv- und negativgelabelten Bildern führt in einer Vorstudie zu unzureichenden Ergebnissen. Die Datenmenge wird in diesen Experimenten ausreichend groß gewählt, um im Kontext einer Machbarkeitsstudie die grundsätzliche Anwendbarkeit des Konzepts zu erforschen. Nähere Untersuchungen decken auf, dass der Erfolg von LIME direkt vom Training des CNN und damit der Verlässlichkeit des Klassifikators abhängt. Diese wird wiederum durch die Vielseitigkeit und der Größe der Trainings- und Validierungsdatensätze beeinflusst. Gerade in komplexeren Anwendungen, so wie in Szenario 2, sind Eingabedaten unerlässlich, die alle möglich auftretenden negativ und positiv assoziierten Konstellationen zeigen. In Abschnitt 4.6 werden ähnliche Aspekte diskutiert, zu denen in Abschnitt 8.3 mögliche Lösungsansätze vorgeschlagen werden.



(a) Beispiel zu Szenario 1 mit $n_{features} = 1$.

(b) Beispiel zu Szenario 2 mit $n_{features} = 3$.

Abbildung 52: Beispiele lokaler Erklärungen beider Szenarien nach der Optimierung [86].

6.5 DISKUSSION UND WEITERE ANWENDUNGSGBIETE

Die durchgeführten Experimente belegen eindrücklich, wie Ausführungsumgebungen, in denen Roboteraufgabenmodelle Anwendung finden, eigenständig von der Aufdeckung relevanter Prozessdetails profitieren können. Die Anwendung des Gesamtkonzepts in einer weiteren Domäne dient dabei nicht allein der Demonstration seiner Anpassungsfähigkeit, sondern liefert auch neue substantielle Erkenntnisse. Durch eine vertiefte Auseinandersetzung mit der Robotik und ihren Herausforderungen kann das Gesamtkonzept um eine zuvor nicht betrachtete Dimension erweitert werden. So können unabhängig vom Akteur (Mensch oder Roboter) Prozessmodelle, die verschiedenen Modellierungsansätzen folgen, durch das Gesamtkonzept optimiert werden. Abbildung 53 zeigt, wie die beiden Domänen Robotik und Prozessmanagement gleichzeitig in der Verbesserungsphase im Kontext von Bilddaten betrachtet werden können. Dabei kann die Eingabe eines der folgenden Prozessmodelle sein:

- Ein Prozessmodell, das nur für Menschen ausführbare Aufgaben enthält (MPM).
- Ein Roboterprozessmodell, das nur für Roboter ausführbare Aufgaben enthält (RPM).
- Ein Prozessmodell, das Arbeitsanweisungen sowohl für Menschen, als auch für Roboter enthält (PM). Es existiert entweder bereits als Modell für beide Akteure oder es werden mit Hilfe eines vorgeschalteten Modellierungsschritts Aufgaben aus MPM in Roboteraufgaben umgewandelt.

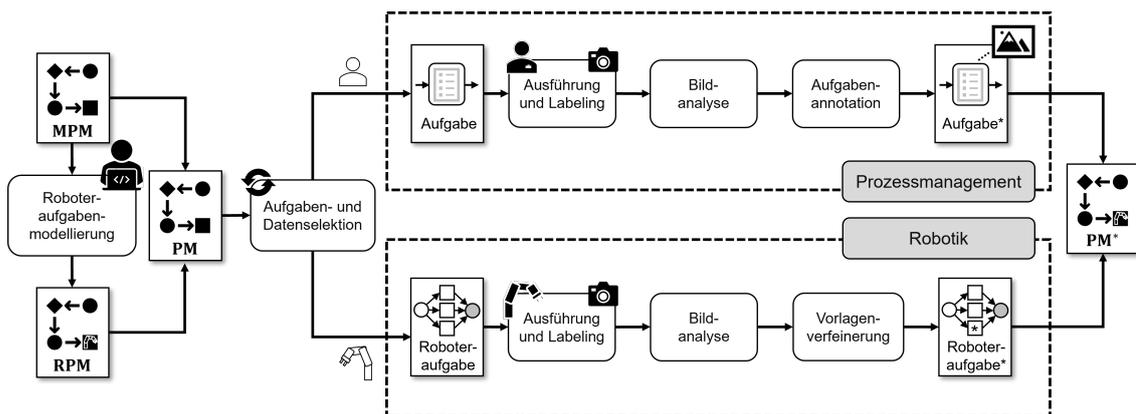


Abbildung 53: Erweiterung der Verbesserungsphase zur Optimierung von Prozessmodellen für Menschen (MPM) und Roboter (RPM) im Sinne eines ganzheitlichen Prozessmodells (PM) nach [86].

Anschließend erfolgen die Schritte der Aufgabenfilterung⁵, sowie Aufgaben- und Daten-selektion. Nach letzterem werden, abhängig vom Typ der auszuführenden Aufgabe und dem beteiligten Akteur, entweder die obere oder die untere Variante des Prozesses initiiert. Im Falle menschlicher Arbeitskräfte erfolgt der weitere Durchlauf der Verbesserungsphase entsprechend Abschnitt 3.3, während im Falle von Robotern die angepassten Schritte gemäß Abschnitt 6.3.1 durchgeführt werden. Das Ergebnis ist ein Prozessmodell PM^* , in dem durch wiederholtes Anwenden der Verbesserungsphase sowohl Roboter- als auch menschliche Aufgabenanweisungen mit relevanten Prozessdetails angereichert sind. Die Möglichkeit zur gleichmäßigen Verarbeitung beider Aufgabentypen eröffnet neue Potenziale im Kontext der Mensch-Roboter-Kollaboration. Dieser Aspekt veranschaulicht, wie verschiedene Domänen durch Anwendung des Konzepts voneinander profitieren können. Dies fördert einerseits die Weiterentwicklung des Ansatzes und trägt andererseits zu interdisziplinären Forschungsgebieten innerhalb der Domänen bei.

Neben der Robotik existieren weitere Anwendungsbereiche aus der Großindustrie sowie kleinen und mittelständischen Unternehmen, welche das entwickelte Gesamtkonzept effektiv einsetzen können. Für die Übertragbarkeit gilt dabei als Vorbedingung, dass Prozessmodelle zur Dokumentation der Prozessschritte verwendet und Ausführungsdaten gesammelt werden. Aus diesem Grund stellt die Analyse der Anwendungsbereiche von Process Mining (Abschnitt 2.1.2) einen sinnvollen Anhaltspunkt dar, da dort vergleichbare Vorbedingungen gelten. Dabei kommt Process Mining besonders verstärkt in folgenden Bereichen zum Einsatz [231]: Gesundheitswesen, Informationstechnologie, herstellendes Gewerbe, Erziehungswesen, Finanzwesen und Logistik. Weiter aber schwächer vertreten sind Bereiche wie Robotik, Biologie, pharmazeutische und chemische Industrie, Textil- und Lebensmittelindustrie. Die effektive Anwendung des Gesamtkonzepts unter Berücksichtigung der notwendigen Anpassung der Verbesserungsphase aus Abschnitt 6.1 ist auch in diesen Domänen denkbar. Gerade im Kontext von Produktindividualisierung und zugeschnittenen Lösungen werden viele Prozessschritte manuell von Menschen ausgeführt [101]. Beispiele hierfür sind vor allem in der Schuh- und Lebensmittelproduktion zu finden [148, 234]. So könnte auch in diesen Prozessen, folgend den Experimenten dieser Arbeit, durch die Extraktion relevanter Prozessdetails basierend auf Bildern eine Optimierung erfolgen. In der Pharmazie und Chemieindustrie können dagegen beispielsweise Videodaten zur Extraktion relevanter Informationen von besonderem Nutzen sein. Die Analyse spezifischer Substanzen kann zahlreiche manuelle Schritte erfordern [68]. Hierbei kann insbesondere die Sequenz der Schritte von erheblicher Bedeutung sein, wobei

⁵Dieser Schritt ist zur kompakteren Darstellung in Abbildung 53 weggelassen worden, folgt aber der Definition von Abschnitt 3.3.1 unter Einbezug von Prozess- und Domänenwissen.

durch Verwendung des Konzepts mit Videodaten noch unbekannte Prozessdetails aufgedeckt werden könnten. In Branchen wie dem Finanzwesen und der Informationstechnologie sind Ausführungsdaten überwiegend in Form von Programmausgaben vorhanden. Hierzu zählen beispielsweise Transaktions- und Buchhaltungsdaten sowie Informationen über Benutzer, deren Verhaltensweisen und Netzwerkprotokolle. In derartigen Szenarien erfolgt die Ausführung sämtlicher Prozesse innerhalb geschlossener Systeme, die von extern nicht sichtbar sind. Dies führt dazu, dass die in Abschnitt 3.5 behandelte Sensorik nur eingeschränkt oder gar nicht zum Einsatz kommt. Nichtsdestotrotz eignen sich strukturierte Analyseansätze in solchen Domänen [22, 237, 245], weshalb die Anwendung des Gesamtkonzepts auch in diesen Bereichen erfolgversprechend ist.

Grundsätzlich bedarf die Übertragung des Gesamtkonzepts auf einen neuen Anwendungsbereich mehrere Aspekte, die im Folgenden zusammenfassend aufgezählt werden.

Annahmen und Rahmenbedingungen: Damit das Gesamtkonzept wie in dieser Arbeit beschrieben angewendet werden kann, müssen die in Abschnitt 3.1 und 3.4 erläuterten Annahmen und Vorbedingungen erfüllt sein. Ist beispielsweise die unabhängige Optimierbarkeit der Aufgaben nicht erfüllt oder unbekannt, bedarf es einer verstärkten Fokussierung auf die Validierungsphase. In solchen Fällen ist die Integration von Prozess- und Domänenwissen und damit die Einbindung von FachexpertInnen unverzichtbar.

Gelabelte Prozessdaten: Die Analyse relevanter Prozessdetails verwendet gelabelte Daten aus Prozessausführungen. Dies erfordert zum einen überhaupt die Möglichkeit zur Bewertung der Prozessergebnisse. Zum anderen muss dabei sichergestellt werden, dass alle aufgenommenen Daten bzgl. des gleichen Kriteriums beurteilt werden, z.B. hinsichtlich der Qualität des Prozessergebnisses. Außerdem muss bei der Beurteilung stets der gleiche Maßstab angelegt werden. Aus diesem Grund ist die objektive Beurteilung auf Basis von Messungen zu bevorzugen.

Anpassung der Verbesserungsphase: Bestimmte Schritte der Verbesserungsphase müssen anhand der in Abschnitt 6.1 erläuterten Aspekte angepasst werden. Dafür benötigen einige Schritte mehr oder weniger vertieftes Domänen- und Prozesswissen. Für Anwendungsfälle, die stark an diejenigen aus dieser Arbeit angelehnt sind, ist eine Anwendung (mit kleineren Anpassungen) auch ohne derartige Fachkenntnisse möglich.

6.6 ZUSAMMENFASSUNG

In diesem Kapitel wird am Beispiel der Robotik gezeigt, wie das Gesamtkonzept in weiteren Domänen neben der Fertigungsindustrie angewendet werden kann. Für eine effektive

Übertragbarkeit auf neue Anwendungsfälle muss dafür vor allem die Verbesserungsphase des Konzepts entsprechend modifiziert werden. In ihr werden einzelne Schritte identifiziert, die durch Prozess- und Domänenwissen an den jeweiligen Anwendungsbereich angepasst werden müssen. Es werden Hinweise gegeben, an welchen Stellen Kontextwissen erforderlich ist und gewinnbringend eingesetzt werden kann. Insbesondere für die Anwendung im Kontext neuer Anwendungsfälle sollten diese Aspekte berücksichtigt werden.

Wie diese Anpassungen konkret gestaltet werden können, wird am Beispiel der Robotik demonstriert. Angesichts der Einführung des Roboters als neuen Prozessteilnehmer ist eine spezielle Form eines Prozessmodells gefordert, um Aufgabenbeschreibungen zu interpretieren und korrekt auszuführen. In dieser Arbeit werden dafür Präzedenzgraphen gewählt, die ähnlich wie Prozessmodelle für Menschen, generische bzw. abstrakte Aufgabenbeschreibungen durch Objektvorlagen enthalten können. Damit sind Präzedenzgraphen ebenfalls mit der Problemstellung konfrontiert, dass sie nicht alle relevanten Prozessdetails enthalten. Zur Prüfung der Übertragbarkeit des Gesamtkonzepts liegt der Schwerpunkt insbesondere auf dem Analyseschritt. Dieser wird unter Anwendung der Methode mit LIME hinsichtlich datenorientierter relevanter Prozessdetails in zwei Szenarien untersucht. Die Ergebnisse zeigen, dass LIME für die Szenarien teilweise Modifikationen erfordert, um gewinnbringende Ergebnisse zu erzeugen. Trotz eines gut trainierten CNNs müssen Optimierungen bzgl. der Parameterwahl und Segmentierung erfolgen. Zur Umsetzung der Optimierungen wird Kontextwissen über die Objekte verwendet, die im Arbeitsbereich vorliegen. Da dies typischerweise in Prozessumgebungen, in denen Roboter zum Einsatz kommen, verfügbar ist, ist dieser Aspekt nicht als gravierendes Problem zu betrachten. Aufgrund des geringen Aufwands und der teilweise signifikanten Verbesserung durch die Optimierung ist eine Anpassung des Segmentierungsschritts von LIME in dieser Domäne und für vergleichbare Szenarien empfehlenswert.

Neben der Demonstration der Anwendbarkeit des Gesamtkonzepts in der Robotik liefert die Betrachtung dieser Domäne neue Potenziale im Kontext der Mensch-Roboter-Kollaboration. Die damit verbundene Vereinheitlichung domänenspezifischer Terminologien bietet eine neuartige Verbindung der Bereiche Prozessmanagement und Robotik. Dies zeigt, dass das Gesamtkonzept neben der Verbesserung von Prozessmodellen auch noch weitere innovative Facetten mit sich bringen kann. Folglich stellt die Anwendung des Konzepts im Kontext domänenspezifischer Prozessmodelle und -notationen sowie spezieller Ausführungssysteme einen interessanten Forschungsgegenstand für zukünftige Arbeiten dar. Die abschließenden Diskussionen zur Implementierung des Gesamtkonzepts in weiteren Anwendungsgebieten zeigen vielfältige Einsatzmöglichkeiten auf. Dabei müssen bei der praktischen Umsetzung die dort zusammengefassten Aspekte berücksichtigt werden, um die Effektivität des Ansatzes zu gewährleisten.

7 | VERWANDTE ARBEITEN UND EINORDNUNG

Im dieser Forschungsarbeit liegt der Fokus auf Verfahren zur Verbesserung von Prozessmodellen und damit verbunden auch auf der Prozessverbesserung. In Kapitel 2 ist bereits ein grundlegender Überblick zu entsprechenden Methoden gegeben. Dagegen umfasst dieses Kapitel die Ergebnisse einer systematischen Literaturrecherche zu verwandten Ansätzen der vorliegenden Arbeit. In diesem Zusammenhang wird die Arbeit in den aktuellen Stand der Forschung eingeordnet und von bestehenden Vorgehensweisen abgegrenzt. Dafür ist neben der Unterteilung bereits existierender Ansätze in Hinblick auf die inhaltsbezogene und darstellungstechnische Verbesserung von Prozessmodellen eine eingehende Analyse der dafür verwendeten Datenquellen von Bedeutung. Der zugrundeliegenden Problemstellung der vorliegenden Arbeit folgend, können relevante Details zu Prozessen unbekannt sein. Diese Informationen repräsentieren neuartiges Prozesswissen, dessen Entdeckung ausschließlich auf Grundlage entsprechend informationsreicher Daten möglich ist. Daraus ergibt sich eine Unterscheidung bisheriger Ansätze bzgl. der für eine Modellverbesserung betrachteten Daten in intrinsische und extrinsische Verfahren.

7.1 INTRINSISCHE UND EXTRINSISCHE PROZESSMODELL- VERBESSERUNG

Als **intrinsische** Verfahren zur Prozessmodellverbesserung werden Ansätze bezeichnet, die im Prozessmodell enthaltene Informationen nutzen, um das Modell zu verbessern. Dagegen nutzen **extrinsische** Methoden zusätzliche Informationen sowie externe Datenquellen in der Prozessumgebung, um Modelle zu verbessern [81].

Intrinsische Ansätze sind beispielsweise Methoden zur Prozessmodellanalyse oder zur Erzeugung von Prozesssichten mit Abstraktions- und Aggregationsmechanismen [4, 38, 203, 215, 217, 251] (Kapitel 2). Derartige Techniken nutzen lediglich bekannte und eine von vornherein begrenzte Menge an Parametern zur Optimierung. Die inhaltliche Ergänzung neuer Prozessinformationen, die noch nicht im Modell enthalten sind, wird nicht berücksichtigt. Deshalb werden sie in dieser Arbeit nicht weiter beachtet.

Im Gegensatz dazu integrieren extrinsische Ansätze zur Verbesserung von Prozessmodellen zusätzliche Daten und stehen daher in Verbindung mit der vorliegenden Arbeit. Sie können verschiedene Daten sowie Datenquellen berücksichtigen, darunter beispielsweise

- Daten, die während Prozessmodellausführungen gesammelt werden,
- Daten, die Informationen zur Prozessumgebung enthalten, oder
- Daten, die sogar weitgehend prozessunabhängig sind.

Die Betrachtung derartiger Daten eröffnet eine neue Dimension zur Verbesserung von Prozessmodellen, die durch intrinsische Ansätze nicht möglich ist. Zu extrinsischen Verfahren zählen beispielsweise Methoden, die Funktionsweisen von Empfehlungsdiensten (engl. *recommender systems*) mit Prozessmanagement in Verbindung bringen [31, 56, 200]. Sie beziehen Ausführungszeiten, Risikokosten aber auch weitere Aspekte wie persönliche Merkmale, Zufriedenheit oder Verhalten von MitarbeiterInnen ein, um Prozesse und Modelle zu optimieren. Ansätze wie [180, 182] sind ebenfalls als extrinsisch zu klassifizieren. Sie berücksichtigen verschiedene Datenquellen, die für die Charakterisierung eines Prozesses zur Verfügung stehen und generieren Optimierungsvorschläge. Ein weiterer extrinsischer Ansatz ist Process Mining (Abschnitt 2.1.2). Techniken aus diesem Bereich sind eng mit dem entwickelten Konzept verbunden, da sie sich explizit mit der Entdeckung von neuem Prozesswissen und einer inkrementellen inhaltlichen Erweiterung von Prozessmodellen befassen. Dies erfolgt durch die Berücksichtigung von Ereignisprotokollen, die Informationen aus externen Datenquellen enthalten können. Aufgrund der Relevanz dieses Forschungsbereichs für die vorliegende Arbeit erfolgt im Anschluss eine eingehende Analyse bisheriger Vorgehensweisen. Der Fokus liegt auf der präzisen Einordnung des entwickelten Konzepts und der Abgrenzung zu bisherigen Ansätzen.

7.2 PROCESS MINING ALS EXTRINSISCHES VERFAHREN ZUR MODELLVERBESSERUNG

Für eine vergleichende Analyse von Process Mining-Techniken im Kontext dieser Arbeit müssen zunächst zwei Punkte erläutert werden.

1. Im klassischen Process Mining bilden historische Ereignisprotokolle den Ausgangspunkt. Diese werden in der Regel durch die Verwendung von Ausführungssystemen angefertigt und in Form von **XES**-Dokumenten (*eXtensible Event Streams*) abgespeichert [7]. Dieses XML-basierte Format wurde im Jahr 2010 von der ,IEEE Process

‘Mining Task Force‘ als Standard für Austausch und Analyse von Ereignisprotokollen deklariert [6, 103]. Syntax und Semantik der enthaltenen Daten sind fest definiert. Außerdem werde eine Reihe von Attributen festgelegt, die beschreiben welche Prozessinformationen abzuspeichern sind (z.B. ausgeführte Aktivitäten mit Zeitstempel). Entsprechen die Daten, die aus einem Ausführungssystem kommen, nicht diesem Format, sind zusätzliche Schritte erforderlich. Dabei können Ereignisprotokolle aus komplexeren Ausführungsdaten durch **Extraktionstechniken** (engl. *event log extraction*) gewonnen werden. Diese funktionieren beispielsweise auch auf unstrukturierten Daten. Das Ergebnis sind Ereignisprotokolle mit domänenspezifischen Informationen, die zur Berücksichtigung ein umfassenderes Speicherformat benötigen. Dazu sind für XES-Dokumente Erweiterungen entwickelt worden, mit denen zusätzliche Attribute definiert werden können. Allerdings geht auch die Verwendung dieser Erweiterungen mit einer zwingend notwendigen Strukturierung der extrahierten Information einher. In dieser Arbeit wird bewusst auf die Verwendung eines fest definierten Formats als Eingabe für den Analyseschritt verzichtet. Zwar können Ereignisprotokolle ebenfalls als Eingabe dienen, jedoch zielt das Gesamtkonzept auf eine flexiblere Berücksichtigung verschiedener Daten und Datenaspekte ab. Außerdem soll eine breitere Auswahl an Analysemethoden unterstützt werden. Dennoch beinhaltet der Analyseprozess Datenverarbeitungsaufgaben, die mit der Extraktion von Ereignisprotokollen vergleichbar sind. Zudem bedient er sich Analysemethoden, wie sie im Bereich des Process Mining auf Ereignisprotokollen angewandt werden. Beispielsweise ist die Umsetzung des Analyseschritts auf strukturierten Bilddaten aus Abschnitt 4.5 mit der klassischen Vorgehensweise eng verwandt. Zur Abgrenzung werden deshalb sowohl Extraktionsmethoden als auch Analysemethoden aus dem Bereich Process Mining betrachtet.

2. Analyseansätze aus dem Bereich Process Mining lassen sich einem der drei Typen Conformance, Discovery und Enhancement zuordnen (Abschnitt 2.1.2). Unter Verwendung von Conformance-Methoden wird die Übereinstimmung des Kontrollflusses eines Prozessmodells mit der Realität geprüft. Sie sind eher als intrinsische Modelloptimierung zu betrachten. Dort wird durch Wiedereinspielen eines Ausführungsprotokolls in ein Modell überprüft, ob im Modell ein Pfad existiert, der diesen Ablauf abbildet [2]. Dafür müssen die möglichen Informationen (z.B. Aktivitäten), die ein Protokoll tragen kann, bereits im Rahmen des Modells definiert worden sein. Erst dadurch sind sie der Ausführungsumgebung überhaupt bekannt und es wird möglich, dass das Protokoll diese erfassen kann. Somit werden im Kontext solcher Techniken intrinsische Parameter zur Verbesserung von Modellen verwendet und deshalb für die Einordnung dieser Arbeit nicht weiter betrachtet.

Discovery-Ansätze leiten Prozessmodelle auf Basis von Ereignisprotokollen ab [6]. Zwar existiert als Annahme im Gesamtkonzept bereits ein Prozessmodell, dennoch sind solche Techniken mit dem Vorgehen im Analyseschritt vergleichbar. Dieser übernimmt, isoliert betrachtet, in bestimmten Konfigurationen und Szenarien die Aufgabe der Identifikation eines untergeordneten Prozessmodells. Beispielsweise können aus gesammelten Videodaten zu Aufgaben eigenständige Prozesse extrahiert werden, die das Ergebnis von Analysen bzgl. verhaltensorientierter relevanter Prozessdetails sind. Diese Prozesse können diagrammatisch in Form von Submodellen in die Gesamtmodelle zurückgeführt werden. Darüber hinaus verfügen, unabhängig von der Erzeugung von Modellen, Discovery-Ansätze über die Fähigkeit neues Prozesswissen zu extrahieren. Damit lösen sie Aufgaben, die eng mit der Identifikation relevanter Prozessdetails aus Ausführungsdaten verbunden sind.

Während Conformance-Methoden die Übereinstimmung von Realität und Prozessmodell prüfen, passen Ansätze aus dem Enhancement existierende Modelle an. Sie umfassen sowohl Techniken zum Reparieren (engl. *repair*) als auch zum Erweitern (engl. *extension*) von Prozessmodellen [2]. Methoden zum Reparieren modifizieren Modelle, um besser der Realität zu entsprechen. Dagegen reichern Erweiterungsansätze Prozessmodelle auf Basis von Informationen aus Ereignisprotokollen um neue Perspektiven oder externe Informationen an und nutzen dafür verschiedene Repräsentationsmöglichkeiten. Das im Rahmen dieser Arbeit entwickelte Gesamtkonzept folgt insbesondere der letzteren Methodik. Dort werden Aufgaben in Modellen durch relevante Prozessdetails spezifiziert, die aus Ausführungsdaten extrahiert werden. Zur Bewahrung der intuitiven Verständlichkeit von Modellen werden die Details in Form von Aufgabenannotationen integriert.

Zur Einordnung der vorliegenden Arbeit werden folglich Process Mining-Ansätze aus den Bereichen Discovery und Enhancement (darunter Erweiterungsmethoden) sowie Methoden zur Extraktion von Ereignisprotokollen betrachtet. Dabei werden bestehende Ansätze anhand vier Kriterien eingeordnet, die entscheidende Charakteristiken des entwickelten Gesamtkonzepts abbilden:

1. Unterstützung zur Extraktion von neuem bzw. noch unbekanntem Wissen hinsichtlich **mehrerer Prozessperspektiven**.
2. Verwendung **unstrukturierter Daten** aus Prozessausführungen.
3. **Erklärung** einer Prozessmodellverbesserung unter Einbezug des **Prozessergebnisses**.
4. Berücksichtigung der **Lesbarkeit** von Prozessmodellen.

Process Mining-Ansätze	Typ	Multiperspektivität	Unstrukturierte Ausführungsdaten	Prozessergebnis und Erklärung	Lesbarkeit von Prozessmodellen
[138, 211, 271]	X		•		
[204, 205]	X	◦	•		
[137]	X	•	•		
[161, 269]	D	•			
[237, 238]	D	•			•
[289]	X, D	•	•	◦	
[30, 50, 104, 272]	X, D		•		
[139, 145, 230]	X, D	•	•		
[265, 266]	E	•			
[160]	E	◦		•	◦
[40]	E	•		•	◦
[192, 257]	E*			•	
[281]	E*	◦		•	
[93, 106, 207, 261]	E*	•		•	
[159]	D, E			•	

Tabelle 7.1: Übersicht und Einordnung verwandter Process Mining-Ansätze: Discovery (D), Enhancement (E) und Ereignisprotokolleextraktion (X).

Ausgangspunkt für die Untersuchung bilden die betrachteten Arbeiten im Zusammenhang mit industriellen Umgebungen in [145, 162]. Darauf aufbauend wurden durch Vorwärts- und Rückwärtssuchen im Bereich Process Mining relevante Arbeiten ergänzt, wobei der Fokus auf den obigen Kriterien liegt. Tabelle 7.1 umfasst eine Zusammenstellung repräsentativer Arbeiten in diesem Kontext, die mindestens eines dieser Kriterien berücksichtigen. Erfüllte Dimensionen sind schwarz, teilweise erfüllte Dimensionen weiß markiert. Ausgewählte Ansätze werden aufgrund besonderer Merkmale oder ihrer höheren Relevanz für die vorliegende Arbeit in den nachfolgenden Abschnitten erläutert.

7.2.1 MULTIPERSPEKTIVITÄT

Process Mining-Ansätze, welche nicht ausschließlich die funktionale und verhaltensorientierte Perspektive untersuchen, finden sich z.B. in [161, 237, 238, 265, 266, 269]. In [237] wird ein Discovery-Ansatz zur Extraktion regelbasierter Prozessmodelle aus strukturierten Ereignisprotokollen präsentiert, wobei dieser spezifisch die organisatorische Perspektive berücksichtigt. Analog zur entwickelten Methode in Abschnitt 4.5.3 kommt dort Association Rule Mining zum Einsatz, um regelbasierte Strukturen zu generieren. Der Ansatz kann demnach grundsätzlich in das Gesamtkonzept zur Entdeckung organisatorischer Prozessdetails auf strukturierten Daten integriert werden. Dabei ist eine Erweiterung der Daten um das Prozessergebnis und die Integration dieses Ergebnisses in die Analyse

erforderlich. Dieser Aspekt wird gegenwärtig zwar nicht explizit vom Ansatz berücksichtigt, ist jedoch grundsätzlich denkbar. Ein weiteres Konzept wird in [269] beschrieben. Es umfasst ein Rahmenwerk, das explizit verschiedene Aspekte des Ereignisprotokolls mittels entsprechender Methoden analysiert, um mehrere Prozessperspektiven zu entdecken. Dabei werden Implementierungen der Methoden bereitgestellt, die sich auch im Kontext des Gesamtkonzepts zur Analyse verschiedener, relevanter Prozessdetailtypen aus strukturierten Daten eignen können.

Aus dem Bereich Enhancement sind vor allem die Ansätze in [265, 266] hervorzuheben. Sie reichern Prozessmodelle mit Informationen zu Kosten an, die mit der Ausführung von Aktivitäten in Verbindung stehen. Dafür werden, ähnlich wie in der vorliegenden Arbeit, Annotationen verwendet und die Kosten an die entsprechenden Aktivitäten im Modell angehängt. Allerdings werden lediglich textuelle Annotationen betrachtet und keine Aspekte zur Verständlichkeit des so angereicherten Modells diskutiert.

Des Weiteren existieren Ansätze wie [204, 205] aus dem Bereich der Ereignisprotokollextraktion. Diese beschreiben Tools zur Unterstützung der Informationsextraktion aus Daten durch Suchanfragen auf Logdateien. Sie sind damit auf einer höheren Abstraktionsebene angesiedelt und können grundsätzlich Informationen verschiedener Perspektiven betrachten. Allerdings wird dies nicht explizit in den referenzierten Arbeiten untersucht, weshalb die Ansätze bzgl. der Multiperspektivität in Tabelle 7.1 gesondert markiert sind.

7.2.2 UNSTRUKTURIERTE AUSFÜHRUNGSDATEN

Aufgrund des starken Anstiegs unstrukturierter Daten in Prozessumgebungen [61, 71, 165] und den darin enthaltenen wertvollen Informationen haben sich in den vergangenen Jahren einige Process Mining-Ansätze zur Analyse derartiger Daten entwickelt. Diese sind anhand der betrachteten Datenquellen zu unterscheiden. Für die vorliegende Arbeit relevante Vorgehensweisen werden im Folgenden näher betrachtet.

Einige Ansätze untersuchen die Extraktion von Ereignisprotokollen aus Texten [204, 205, 271] oder Aktivitäten aus Daten von (tragbaren) Sensoren [211]. Ebenfalls im Kontext dieser Datenquellen sind Discovery-Techniken zur Erzeugung von Prozessmodellen basierend auf textuellen Daten [30, 230, 289] und Sensordaten [50, 104, 272] entwickelt worden. In diesem Zusammenhang sind die Arbeiten von [252, 258] zu erwähnen, die nicht unter den Begriff ‚Process Mining‘ zu finden und deshalb nicht in Tabelle 7.1 aufgeführt sind. Allerdings nutzen sie ebenfalls Sensordaten, um Aktivitäten in Prozessen sowie ihren Ablauf zu identifizieren. Hervorzuheben sind die Ansätze von [137, 138, 139, 145], welche die Verarbeitung von Videodaten im Kontext von Prozessen zur Identifikation von Aktivitäten betrachten. Sie integrieren vergleichbare Methoden aus dem Bereich der

Bildverarbeitung, wie sie im entwickelten Verfahren in Abschnitt 4.4.3 erörtert werden und lösen damit verbundene Problemstellungen.

Unstrukturierte Sensordaten, Videodaten und Texte sind ebenfalls als Eingabe in das Gesamtkonzept vorgesehen. Die hier betrachteten Verfahren sind somit im Sinne einer Umsetzungsmöglichkeit des Analyseschritts (bzw. Teilschritten davon) einzuordnen. Als entscheidender Unterschied ist jedoch zu betonen, dass keines der Verfahren das Prozessergebnis als weitere Dimension bei der Datenakquise berücksichtigt. Sie fokussieren sich ausschließlich auf die semantische Interpretation der Daten zur Aktivitätsklassifizierung und berücksichtigen keine Zusammenhänge mit dem Prozess Erfolg.

7.2.3 PROZESSERGEBNIS UND ERKLÄRUNG

Unter den Ansätzen, die das Prozessergebnis in ihre Analyse einbeziehen, sind für die vorliegende Arbeit vor allem Techniken von Bedeutung, welche die Gründe für Prozessergebnissen erklären können. Verfahren in diesem Zusammenhang lassen sich im Kontext von Prozessvorhersagen (engl. *process prediction*) [160, 257, 281], von Empfehlungen bzgl. nächster Prozessschritte (engl. *prescriptive analytics*) [192] sowie allgemeiner unter dem Begriff der Fehlerursachenanalyse (engl. *root cause analysis*) in Prozessen identifizieren [40, 93, 106, 159, 207, 261, 289].

Der Großteil der Verfahren wird in dieser Arbeit dem Bereich Enhancement zugeordnet. Allerdings gibt es darunter einige Ansätze, die Informationen ausschließlich in Ausführungssysteme integrieren (markiert als E* in Tabelle 7.1). Beispielsweise kann das System so die Gründe für Vorschläge bzgl. nächster Prozessschritte enthalten, um die Entscheidungsfindung während des Ablaufs zu unterstützen. Sie führen die neu gewonnenen Erkenntnisse nicht in das Prozessmodell zurück und sind damit nicht im Sinne des Enhancement eines Modells zu betrachten. Die in den Arbeiten vorgestellten Techniken bieten allerdings gute Anhaltspunkte für die Entwicklung innovativer Erweiterungsmethoden, worunter einige außerdem die Eignung von XAI zur Fehlerursachenanalyse in Prozessen bestätigen [93, 257, 281].

Unter den Methoden, die gezielt Prozessmodelle auf Basis von Fehlerursachenanalysen erweitern, sind im Kontext dieser Arbeit vor allem die Ansätze von [40] und [160] zu betrachten. In [40] wird ein Ansatz mit Association Rule Mining entwickelt, um den Zusammenhang zwischen Aktivitäten und Anomalien während des Prozessablaufs zu bestimmen. Aktivitäten, die als ursächlich für Prozessfehlschlag identifiziert werden, sind durch Verwendung einer entsprechenden Visualisierungstechnik farblich im Prozessmodell hervorgehoben. In der Arbeit von [160] wird ein Konzept mit LIME entwickelt, um

Vorhersageergebnisse zu Prozessen zu erklären. Vergleichbar zum Ansatz von [40] werden Aktivitäten im Prozessmodell, auf die Erfolg oder Fehlschlag des Prozesses zurückzuführen ist, entsprechend farblich hervorgehoben. Weiter ist die Unterstützung verschiedener Prozessperspektiven lediglich in Form einer Erweiterung als zukünftiges Forschungsvorhaben deklariert. Diese beiden Dimensionen sind somit teilweise erfüllt, weshalb sie in Tabelle 7.1 gesondert markiert sind.

Die in den Arbeiten von [40, 160] eingesetzten Techniken (Association Rule Mining und LIME) werden auch in den entwickelten Methoden in Abschnitt 4.4.3 und 4.5.3 verwendet. Die Ansätze sind damit eng mit der vorliegenden Arbeit verwandt, haben aber einen anderen Fokus. Sie zielen darauf ab, Erklärungen durch Betrachtung des Einflusses der Anwesenheit bzw. Abwesenheit modellierter Aspekte auf den Prozesserfolg zu finden. Dagegen findet das in der vorliegenden Arbeit entwickelte Gesamtkonzept Erklärungen für Prozesserfolg in noch nicht modellierten Informationen. Diese werden genutzt, um bereits modellierte Aspekte nachhaltig anzureichern. Dabei liegt ein weiterer essenzieller Unterschied in der Betrachtung der Daten, auf deren Basis die Analysen durchgeführt werden. Die Ansätze von [40, 160] nutzen strukturierte Ereignisprotokolle, genauso wie die meisten der o.g. anderen Ansätze im Zusammenhang mit Fehlerursachenanalyse bzw. der Erklärbarkeit von Prozessergebnissen. Sie berücksichtigen keine unstrukturierten Datenbestände oder externen Datenquellen. Damit sind die angeführten Methoden auch in dieser Dimension von der vorliegenden Arbeit abzugrenzen. Allerdings stellen sie Anhaltspunkte für alternative Umsetzungen des Analyseschritts auf Basis strukturierter Daten dar. Der Ansatz von [289] zeichnet sich als eine der wenigen Methoden in diesem Bereich aus, der auch unstrukturierte Daten betrachtet. Es sei jedoch darauf hingewiesen, dass in dieser Arbeit die Eignung des Ansatzes zur Fehlerursachenanalyse lediglich erwähnt wird, ohne dass eine praktische Demonstration oder detaillierte Erläuterung erfolgt. Aufgrund dieses Umstands ist dieser Ansatz in Tabelle 7.1 speziell markiert.

7.2.4 LESBARKEIT VON PROZESSMODELLEN

Etablierte Forschungsansätze, welche gezielt die Lesbarkeit von Prozessmodellen aus verschiedenen Blickwinkeln untersuchen, werden in Abschnitt 5.1 vorgestellt. Im Kontext von Enhancement- oder Discovery-Methoden findet dieser Aspekt in nur wenigen Ansätzen Beachtung [40, 160, 237, 238]. In [40, 160] werden Visualisierungstechniken gewählt, um die analysierten Informationen im Modell interpretierbar zu machen. Allerdings wird die Verständlichkeit der Visualisierung oder der so veränderten Modelle nicht explizit untersucht. Aus diesem Grund berücksichtigen die Ansätze diese Dimension nur teilweise. Dagegen werden in [237, 238] gezielt Methoden eingesetzt, um redundante Informa-

tionen in den extrahierten Prozessmodellen zu reduzieren. Dies dient der Erhöhung der Verständlichkeit der extrahierten Modelle. Der Ansatz folgt damit, genauso wie die vorliegende Arbeit, dem Modellierungsparadigma, ausschließlich notwendige Informationen in Prozessmodellen abzubilden. Die Betrachtung aller Ansätze hinsichtlich der Erfüllung dieser Dimension deutet darauf hin, dass Optimierungen zu Inhalt und Lesbarkeit häufig getrennt voneinander vorgenommen werden. Im Gegensatz dazu berücksichtigt das Design des Gesamtkonzepts beide Aspekte gleichzeitig und untersucht darüber hinaus in der durchgeführten Nutzerstudie explizit, wie die Lesbarkeit von Prozessmodellen im Zusammenhang mit relevanten Prozessdetails erhöht werden kann (Abschnitt 5.2).

7.3 ABGRENZUNG ZU GANZHEITLICHEN ANSÄTZEN

Die meisten der in den vorherigen Abschnitten genannten Ansätze beschreiben Möglichkeiten zur Umsetzung einzelner Schritte des entwickelten Gesamtkonzepts. Des Weiteren basieren sie oft auf der Verwendung von Ereignisprotokollen aus Ausführungssystemen. Von besonderer Bedeutung ist deshalb die Abgrenzung von anderen ganzheitlichen Ansätzen wie [180, 289], welche alternative Datenquellen berücksichtigen.

Die Arbeit von [180] stellt einen extrinsischen Modelloptimierungsansatz dar, der sich auf graduelle und evolutionäre Optimierungsmethoden stützt. Dabei berücksichtigt die entwickelte Plattform verschiedene Prozessperspektiven und betrachtet Prozessdaten aus dem klassischen Ausführungssystem kombiniert mit operativen Daten (z.B. Kundendaten) aus anderer Software. Der Analyseprozess identifiziert Verbesserungspotenziale bzgl. eines gewählten Kriteriums (z.B. Kosten oder Qualität) und schlägt dazu verschiedene Muster zur Anpassung eines Prozessmodells vor. Diese können von ProzessanalystInnen semi-automatisch übernommen werden. Der grundlegende Aufbau des Ansatzes weist eine starke strukturelle Ähnlichkeit zu den drei Phasen des entwickelten Gesamtkonzepts dieser Arbeit auf. Zur Implementierung der Verbesserungsanalyse werden dabei genauso regelbasierte Data Mining-Techniken angewendet, wie beispielsweise Association Rule Mining. Dennoch lassen sich deutliche Unterschiede der beiden Konzepte identifizieren. Zum einen fokussiert sich der Ansatz von [180] auf die Rückführung der neu gewonnenen Information durch die Anpassung der Struktur eines Prozessdiagramms. Andere Repräsentationsformate wie beispielsweise im Kontext von Media-Annotationen zur Integration von neugewonnener Information werden nicht in Betracht gezogen. Damit verbunden wird auch die Bewahrung der Verständlichkeit des angereicherten Modells nicht explizit berücksichtigt. Zum anderen werden zwar externe Datenquellen einbezogen, darunter ist aber nicht die Verarbeitung von unstrukturierten Daten vorgesehen. Dies stellt einen

wichtigen Aspekt zur Identifikation aller potenziell relevanten Prozessinformationen dar, wobei die Autoren die Einbindung verschiedener Quellen befürworten. In diesem Kontext ist das entwickelte Gesamtkonzept als Erweiterung des Ansatzes von [180] zu betrachten.

Der vorgestellte Systementwurf in [289] zielt auf die Analyse von Herstellungsprozessen ab und fokussiert dabei die effektive Verwendung großer Datenmengen. Er extrahiert Ereignisprotokolle aus verschiedenen Datenquellen (darunter auch Sensoren) und berücksichtigt sowohl explizit strukturierte als auch unstrukturierte Daten. Auf Grundlage dieser Informationen generiert das System ein Prozessmodell und führt mithilfe von Process Mining-Methoden verschiedene Leistungsanalysen durch, um Schwachstellen zu identifizieren. Außerdem zielt der Ansatz darauf ab, Erklärungen für die Ursachen von Leistungseinbrüchen zu finden. Ein Vergleich mit der vorliegenden Arbeit offenbart einige Ähnlichkeiten in der Herangehensweise und der Berücksichtigung verschiedener Aspekte (vgl. Tabelle 7.1). Dabei ist besonders die gezielte Unterstützung der Analyse durch die Integration sowohl strukturierter als auch unstrukturierter Daten hervorzuheben, was den Ansatz von allen anderen betrachteten Methoden deutlich unterscheidet. Allerdings sieht das Konzept in [289] nicht vor, die analysierte Information in das Modell zurückzuführen, um nachhaltig den Prozesserfolg zu erhöhen. Des Weiteren ist das System spezifisch auf die Fertigungsdomäne ausgerichtet und eine Abstraktion des Konzepts zur Berücksichtigung anderer Prozessdomänen nicht vorgesehen. Diese Aspekte verdeutlichen die Adressierung einer anderen Problemstellung im Vergleich zu der vorliegenden Arbeit, was die beiden Ansätze deutlich voneinander abgrenzt. Nichtsdestotrotz liefert die Arbeit von [289] neue Ideen und Anregungen für eine effektive Umsetzung und Weiterentwicklung des Gesamtkonzepts im Kontext von Herstellungsprozessen.

8 | FAZIT UND AUSBLICK

In diesem Kapitel wird die Problemstellung sowie der konzipierte Lösungsansatz dieser Arbeit zusammengefasst. Dabei werden Vorgehensweise, entwickelte Methoden, durchgeführte Experimente und erzielte Ergebnisse erläutert. Basierend darauf werden Schlussfolgerungen gezogen, die bei der Umsetzung des entwickelten Gesamtkonzepts zu beachten sind. Den Abschluss bildet ein Ausblick auf weiterführende Forschung im Kontext der Dissertation. Er umfasst mögliche Erweiterungen des Konzepts und damit verbundene Untersuchungen sowie Anregungen zur Überwindung bestehender Einschränkungen.

8.1 ZUSAMMENFASSUNG

Damit Prozessmodelle effektiv Abläufe in Unternehmen unterstützen können, müssen sie sowohl wichtige Inhalte von Prozessen abbilden als auch für die Prozessausführenden verständlich sein. Allerdings sind nicht immer alle Prozessinformationen bekannt oder können nicht adäquat durch etablierte Modellierungssprachen in einem Modell abgebildet werden. Zudem stellt die gleichzeitige Berücksichtigung des Inhalts und der Verständlichkeit bei der Modellierung eine herausfordernde Aufgabe dar. Allgemeine Modellierungsrichtlinien bieten hierfür keine ausreichende Unterstützung, da Designentscheidungen individuell für jeden Prozess getroffen werden müssen. Die Folge sind entweder informationsüberladene, unverständliche oder zu abstrakte Modelle, die nicht alle Informationen enthalten, da zugunsten der Lesbarkeit auf einen hohen Informationsgehalt verzichtet wird. Existierende Ansätze zur Verbesserung von Prozessmodellen konzentrieren sich häufig nur auf einen dieser Aspekte und betrachten das Problem nicht ganzheitlich.

Diese Problematik kann durch die Berücksichtigung relevanter Prozessdetails gelöst werden. Sie beschreiben essenzielle Informationen eines Prozesses, die zwingend im Modell enthalten sein müssen, um Prozesserfolg zu erreichen. Dabei kann der Erfolg eines Prozesses anhand verschiedener Kriterien bestimmt werden, z.B. durch die Qualität der Prozessergebnisse. Die Integration ausschließlich relevanter Informationen verhindert eine Informationsüberladung der Prozessmodelle, wobei gleichzeitig die Verständlichkeit erhalten bleibt. Den Prozessausführenden werden alle Informationen bereitgestellt, die

für eine erfolgreiche Ausführung nötig sind. Die systemgestützte Identifikation relevanter Prozessdetails und deren Integration in ein Prozessmodell schließen eine Forschungslücke im Bereich Prozessmodellverbesserung. Die vorliegende Arbeit adressiert damit verbundene Forschungsfragen durch die Entwicklung eines Gesamtkonzepts, mit dem Prozessmodelle inkrementell durch relevante Prozessdetails verbessert werden. Das vorgestellte Gesamtkonzept umfasst dabei drei Phasen:

1. Die Beobachtungsphase, in der ein unzureichender Informationsgehalt eines Prozessmodells aufgrund von Abweichungen im Prozessergebnis festgestellt wird.
2. Die Verbesserungsphase, in der relevante Prozessdetails identifiziert und in das Prozessmodell zurückgeführt werden.
3. Die Validierungsphase, in der das verbesserte Prozessmodell geprüft wird und die Verbesserungsphase für weitere Untersuchungen erneut angestoßen werden kann.

Die Verbesserungsphase bildet mit dem enthaltenen Analyse- und Annotationsschritt das Kernstück des Konzepts. In dieser Phase werden zu einer, in einem Prozessmodell definierten, Aufgabe Ausführungsdaten aus Datenquellen gesammelt und am Ende jeder Modellausführung hinsichtlich des Prozessenerfolgs beurteilt. Der Analyseschritt untersucht anhand der so gelabelten Daten, ob die Beschreibung der betrachteten Aufgabe zu generisch ist und relevante Prozessdetails fehlen. Er adressiert dabei die Herausforderung, verborgene und noch unbekannt Informationen aus den vorliegenden Daten zu extrahieren und deren Zusammenhang mit Prozessenerfolg zu erklären. Dafür müssen sämtliche, im Kontext der Ausführung anfallende, Daten in Betracht gezogen werden, weshalb das Gesamtkonzept auf die Verarbeitung verschiedener Datenquellen und -strukturen ausgelegt ist. Dies stellt einen signifikanten Unterschied zu anderen Ansätzen dar, die häufig auf die Extraktion von Wissen aus Ereignisprotokollen abzielen, welche a priori in ihrem Informationsgehalt begrenzt sind. Das Ergebnis der Analyse sind Regeln mit Bedingungen, die während der Ausführung der betrachteten Aufgabe erfüllt sein müssen, um insgesamt den Prozessenerfolg zu erhöhen. Anschließend wird die neu gewonnene Information in eine Aufgabenannotation umgewandelt und die Aufgabenbeschreibung durch deren Integration in das Modell spezifiziert. Dabei unterstützt der Annotationsschritt verschiedene Repräsentationsformate (Text, Bild, Diagramm) und zielt darauf ab, das relevante Detail intuitiv verständlich im Prozessmodell darzustellen.

Zur Entwicklung des Gesamtkonzepts und seiner beispielhaften Umsetzung erfolgt die Einbindung verschiedener wissenschaftlicher Disziplinen, die für das Ziel der Prozessmodellverbesserung im Kontext Prozessmanagement miteinander verknüpft werden. Dabei kommen Techniken aus der künstlichen Intelligenz, Mustererkennung, Robotik,

Bildverarbeitung, Datenanalyse und empirischer Sozialforschung zum Einsatz. Sie werden genutzt, um die Umsetzbarkeit des Analyse- und Annotationsschritts der Verbesserungsphase zu demonstrieren. Zudem sind sie entscheidend für die Effektivität des Gesamtkonzepts, weshalb der Fokus dieser Arbeit auf der Entwicklung dafür geeigneter Methoden liegt. Die Funktionalität des Analyseschritts wird am Beispiel von Bilddaten illustriert. Dazu werden synthetische Bilder generiert, die typische Platzierungsszenarien aus dem Fertigungsbereich abbilden. In Experimenten wird untersucht, wie relevante Informationen zu den Objekten in der Szene extrahiert werden können. Zu diesem Zweck werden zwei Methoden entwickelt und prototypisch implementiert. Die Methoden nutzen einerseits LIME, einen etablierten Ansatz aus dem Bereich der erklärbaren künstlichen Intelligenz, und andererseits Association Rule Mining, ein regelbasiertes Analyseverfahren zur Aufdeckung von Zusammenhängen in Prozessdaten. Um zu evaluieren, wie im Kontext des Annotationsschritts relevante Prozessdetails durch Aufgabenannotationen intuitiv verständlich in Modellen dargestellt werden können, wird eine experimentelle Nutzerstudie konzipiert und durchgeführt. Intuitiv verständliche Arbeitsanweisungen sind essenziell für eine effektive und effiziente Prozessausführung. Ziel ist deshalb die Bereitstellung von Empfehlungen, welches Repräsentationsformat bei bestimmten Aufgabenstellungen gewählt werden sollte. Das innovative Studiendesign sowie die verwendeten und entwickelten Messinstrumente ergänzen bisherige Methoden, die nicht alle Aspekte intuitiver Verständlichkeit einbeziehen. Die Anwendbarkeit des Gesamtkonzepts auf ähnliche Problemstellungen im Kontext weiterer Domänen wird am Beispiel der Robotik demonstriert. Es wird veranschaulicht, wie insbesondere der Analyse- und Annotationsschritt modifiziert und genutzt werden kann, um auch Roboteraufgabenmodelle mit relevanten Prozessdetails gewinnbringend anzureichern.

8.2 SCHLUSSFOLGERUNGEN

Basierend auf den durchgeführten Evaluationen lässt sich zusammenfassen, dass das Gesamtkonzept eine Erfolg versprechende Vorgehensweise zur Verbesserung von Prozessmodellen darstellt. Die Ergebnisse der Experimente bestätigen die Effektivität und Umsetzbarkeit des Analyseschritts für die entwickelten Methoden und den Versuchsaufbau. Es wird erfolgreich demonstriert, wie relevante datenorientierte Prozessdetails einerseits direkt aus unstrukturierten Bilddaten und andererseits aus Überführung in ein strukturiertes Format extrahiert werden können. Dabei wird ersichtlich, dass die Wahl geeigneter Hyperparameter für die verwendeten Techniken entscheidend für eine erfolgreiche Detailanalyse ist. Außerdem muss bei der Anwendung ein ausreichender Datenbestand mit

qualitativ hochwertigen Daten bereitgestellt werden. Bei Unternehmen, in denen der zu analysierende Prozess beispielsweise aufgrund geringer Produktionsmengen nur selten ausgeführt wird, können jedoch nur wenig Daten gesammelt werden. Für solche Fälle zeigen die Ergebnisse der Experimente, dass unter den entwickelten Analysemethoden der Ansatz mit Association Rule Mining zu bevorzugen ist. Darüber hinaus eignen sich grundlegend beide Methoden für die Extraktion anderer Typen relevanter Prozessdetails, z.B. für operationale Details. Dafür wird der Fokus auf andere Inhalte der Daten gelenkt und die Methoden werden entsprechend konfiguriert. In diesem Kontext sind auch andere Datenquellen und Daten in Betracht zu ziehen.

Die Auswertungen der experimentellen Nutzerstudie im Rahmen des Annotations-schritts ergeben, dass bildbasierte Aufgabenannotationen zur Repräsentation relevanter Prozessdetails allgemein zu bevorzugen sind. Diese Empfehlung gilt für die Bereitstellung von Aufgabenannotationen für Prozessteilnehmende mit und ohne Erfahrung im Bereich Prozessmodellierung bzw. -ausführung und unabhängig von ihrem Bildungsgrad. Dabei ist bei bildgestützten Annotationen zu beachten, dass die beschriebenen Anweisungen nicht immer eindeutig interpretiert werden. Zwar wird dadurch nicht der Prozessserfolg generell in Frage gestellt, dennoch kann die Effizienz der Ausführung verringert werden.

Die Anwendung am Beispiel der Robotik zeigt, dass das Gesamtkonzept nicht auf eine bestimmte Domäne oder Prozessmodellierungssprache beschränkt ist. Es basiert auf einer abstrakten und modularen Architektur, deren Elemente je nach Anwendungsfall angepasst werden können. Dabei stehen insbesondere die Schritte der Verbesserungsphase im Fokus, die unter Berücksichtigung von Fachwissen modifiziert werden müssen. Dies muss bei der Übertragung auf neue Domänen und Prozesse gemeinsam mit den in dieser Arbeit geltenden Annahmen und Rahmenbedingungen beachtet werden.

8.3 ZUKÜNFTIGE FORSCHUNGSTHEMEN

Ziel der Dissertation ist die Entwicklung eines initialen und grundlegenden Konzepts, das die Extraktion relevanter Prozessdetails und deren Integration in Prozessmodelle unterstützt. Der Fokus wird dabei auf die Überprüfung der Methodik im Sinne einer Machbarkeitsstudie gelegt. Damit bildet die Arbeit eine Grundlage für weiterführende Untersuchungen, die das Konzept aus verschiedenen Blickwinkeln verbessern und erweitern können. Im Rahmen der durchgeführten Evaluationen ergeben sich neue interessante Fragestellungen, die als Grundlage für zukünftige Arbeiten dienen können. Nachfolgend sind wesentliche Aspekte nach inhaltlich verschiedenen Themenbereichen gruppiert.

ERWEITERUNGEN DER METHODIK ZUR ANALYSE RELEVANTER PROZESSDETAILS

- Neben LIME existieren viele weitere Methoden aus dem Bereich XAI zur Erzeugung lokaler Erklärungen (Abschnitt 4.4.1.2). Dabei werden in [48] verschiedene Ansätze evaluiert, wobei die Methode *Gradient-Weighted Class Activation Mapping* (Grad-CAM) die besten Ergebnisse erzielt. Im Vergleich zu LIME visualisiert Grad-CAM nicht nur die Auswirkungen einer Bildregion auf eine Entscheidung, sondern veranschaulicht zusätzlich die Intensität des Zusammenhangs. Ein derartiger Ansatz kann gerade in komplexeren Szenarien hilfreich sein und sollte bzgl. dieses Aspekts untersucht werden. In diesem Kontext sollte auch die Anwendbarkeit globaler Erklärungsmethoden wie *deep visualization* [290] oder BETA [150] für die Extraktion relevanter Prozessdetails evaluiert werden. Derartige Ansätze eliminieren die Notwendigkeit des Globalisierungsschritts, überwinden damit verbundene Probleme und stellen einen interessanten Forschungsaspekt für die Verarbeitung unstrukturierter Prozessdaten dar.
- Der Ansatz mit Association Rule Mining bestimmt die relevante Regel durch die Berechnung von Metriken (Abschnitt 4.5.3). Die Evaluationsergebnisse zeigen jedoch, dass die betrachteten Metriken in Verbindung mit dem Experimentaufbau die Selektion einer Regel nicht effektiv unterstützen. Daher sind weitere Untersuchungen erforderlich, die alternative Metriken oder Methoden zur Identifizierung relevanter Regeln in Betracht ziehen. Die Anwendung weiterer Algorithmen, insbesondere für das komplexere Szenario, ist ebenfalls von Interesse. Um die Effektivität des evolutionären Algorithmus GAR+ genauer zu bestimmen, sind zudem weitere Experimente nötig, die seine nichtdeterministische Eigenschaft berücksichtigen.
- In der vorliegenden Arbeit werden Ausführungsdaten anhand zweier Klassen gelabelt (Prozesserfolg und Prozessfehlschlag). Dabei ist der Analyseschritt grundsätzlich auch auf die Betrachtung mehrerer Klassen ausgelegt. Zukünftige Experimente sollten untersuchen, ob durch den Einbezug mehrerer Klassen (z.B. verschiedene Stufen oder Dimensionen des Prozesserfolgs) neue Anforderungen an eine effektive Analyse relevanter Informationen entstehen. Dieser Aspekt bezieht auch die Diskussion ein, welche Informationen dann in das Prozessmodell zurückgeführt werden.

WEITERE UNTERSUCHUNGEN ZUR INTUITIVITÄT VON AUFGABENANNOTATIONEN

- Die Ergebnisse der experimentellen Nutzerstudie in Kapitel 5 betonen die intuitive Verständlichkeit von bildbasierten Aufgabenannotationen. Dabei gibt es innerhalb der Verwendung von Bildern verschiedene Möglichkeiten, Aufgabenanweisungen zu beschreiben. Für die gewählte Darstellung in der Studie waren die TeilnehmerInnen bestrebt, die

gezeigten Szenen präzise im Arbeitsraum nachzubilden. Dabei interpretierten sie dieses Verhalten häufig als eine durch das Bild vermittelte verpflichtende Anweisung, was vom Studiendesign nicht beabsichtigt war. Folgestudien sollten daher untersuchen, wie Informationen in Bildern dargestellt werden können, um gewünschte Interpretationen zu erzielen. Insbesondere im Kontext von Prozessen steht dies im Zusammenhang mit der Effizienz eines Ablaufs, weshalb eine optimale und kontrollierte Kommunikation der Inhalte gewährleistet werden muss.

- In Ergänzung zu den vorliegenden Untersuchungen sollten zukünftige Studien darüber hinaus die Verständlichkeit von Aufgabenannotationen im Zusammenhang mit komplexeren Szenarien aus der Praxis evaluieren. Die Berücksichtigung dieses Aspekts ist von besonderer Relevanz für die Ableitung von allgemeinen Schlussfolgerungen im Kontext realer Prozessumgebungen. Dabei sollten für eine noch präzisere Schlussfolgerung die Gruppe der erfahrenen StudienteilnehmerInnen im Bereich Prozessmodellierung und Prozessausführung Personen umfassen, die in der betrachteten Domäne tatsächlich tätig sind. Sie beschreiben unter anderem die Zielgruppe für welche die Aufgabenannotationen erzeugt werden, weshalb ihre Beurteilungen für den Vergleich mit Personen ohne Erfahrung eine genauere Erfassung der Unterschiede ermöglicht.

ERWEITERUNGEN DES GESAMTKONZEPTS IM KONTEXT REALER PROZESSE

- Wie in den Abschnitten 3.1 und 3.4 erläutert, ist die Effektivität des Gesamtkonzepts an Bedingungen und Voraussetzungen gebunden. Um das Konzept für einen möglichst breiten Anwendungsbereich nutzbar zu machen, ist es erforderlich, diese zu reduzieren. Hierfür bedarf es weiterführender Untersuchungen, die (i) darauf abzielen, das Konzept zu erweitern oder zu modifizieren und somit designbedingte Einschränkungen zu verringern, oder (ii) Methoden zu finden, welche die Erfüllung der erforderlichen Bedingungen unterstützen. Zum Beispiel können im Zusammenhang mit der Voraussetzung einer ausreichenden Datenmenge *Data Augmentation*-Methoden zur künstlichen Vergrößerung des Datensatzes einen zielführenden Beitrag leisten [247]. Alternativ kann auch die Verwendung von vortrainierten neuronalen Netzen aus ähnlichen Domänen und Prozessen dazu beitragen, diese Herausforderung zu bewältigen [79].
- Zur Bestimmung relevanter Details untersucht der Analyseschritt den Zusammenhang zwischen erfolgreichen Ausführungen und Elementen der Arbeitsumgebung. Das Ergebnis ist eine Regel, welche Bedingungen erhält, die zur Erreichung von Prozess Erfolg zwingend erfüllt sein müssen. Allerdings ist ihr nicht zu entnehmen, welche Aktionen während der Ausführung zwingend vermieden werden müssen. Diese Informa-

tion kann durch Analyse des Zusammenhangs von Merkmalen mit Prozessfehlschlag (anstatt Prozesserfolg) extrahiert werden. Ergänzend zu der bisherigen Vorgehensweise können Aufgabenanweisungen so noch weiter präzisiert werden, was im Rahmen einer Erweiterung des Konzepts zu evaluieren ist.

- Die Ergebnisse in Kapitel 4 belegen die Wirksamkeit der Analyseverfahren für synthetisch generierte Bilddaten. Für eine abschließende Bewertung der Praxistauglichkeit dieser Methoden sind jedoch weitere Untersuchungen mit realen Prozessdaten und weiteren Szenarien erforderlich. Insbesondere ist dabei zu prüfen, wie robust die Methoden gegenüber Störungen sind, die üblicherweise in realen Datensätzen auftreten. Weiter sollten zukünftige Arbeiten die Eignung bisheriger Methoden sowie die Verwendung alternativer Ansätze zur Extraktion weiterer Typen relevanter Prozessdetails berücksichtigen. Dabei sollten außerdem zusätzliche Datenquellen einbezogen werden.
- Die entwickelte Methode mit LIME umfasst einen Globalisierungsschritt zur Regelerzeugung durch Aggregation lokaler Erklärungen (Abschnitt 4.4.3). Dieser Schritt wird zur Demonstration der Effektivität der Methode mit LIME prototypisch implementiert. Ein nächster Schritt bzgl. der Anwendung dieser Methode besteht in der Umsetzung der in Abschnitt 4.4.3.2 beschriebenen komplexeren Variante. Außerdem ist die umfassende Realisierung des Gesamtkonzepts, inklusive eines Systems zur Datenaufnahme, durchzuführen und ganzheitlich unter Einbezug aller drei Konzeptphasen zu evaluieren.

LITERATUR

- [1] Van der Aalst, W.M.: Business process management demystified: A tutorial on models, systems and standards for workflow management. Lectures on concurrency and Petri nets **3098**(3098), 1–65 (2004)
- [2] Van der Aalst, W.M.: Process Mining: Discovery, Conformance and Enhancement of Business Processes, vol. 136. Springer Berlin, Heidelberg (01 2011). doi: 10.1007/978-3-642-19345-3
- [3] Van der Aalst, W.M.: What makes a good process model? Lessons learned from process mining. *Software & Systems Modeling* **11**(4), 557–569 (2012)
- [4] Van der Aalst, W.M.: Business process management: a comprehensive survey. *International Scholarly Research Notices* **2013** (2013)
- [5] Van der Aalst, W.M.: Data Science in Action, pp. 3–23. Springer Berlin Heidelberg, Berlin, Heidelberg (2016). doi: 10.1007/978-3-662-49851-4_1
- [6] Van der Aalst, W.M., Adriansyah, A., De Medeiros, A.K.A., Arcieri, F., Baier, T., Blickle, T., Bose, J.C., Van Den Brand, P., Brandtjen, R., Buijs, J., et al.: Process mining manifesto. In: *Business Process Management Workshops: BPM 2011 International Workshops, Clermont-Ferrand, France, August 29, 2011, Revised Selected Papers, Part I* 9. pp. 169–194. Springer (2012)
- [7] Van der Aalst, W.M., Carmona, J.: *Process mining handbook*. Springer Nature (2022)
- [8] Van der Aalst, W.M., Jablonski, S.: Dealing with workflow change: identification of issues and solutions. *Computer systems science and engineering* **15**(5), 267–276 (2000)
- [9] Van der Aalst, W.M., Ter Hofstede, A.H.: YAWL: yet another workflow language. *Information systems* **30**(4), 245–275 (2005)
- [10] Van der Aalst, W.M., Van Hee, K.M., Ter Hofstede, A.H., Sidorova, N., Verbeek, H., Voorhoeve, M., Wynn, M.T.: Soundness of workflow nets: classification, decidability, and analysis. *Formal aspects of computing* **23**, 333–363 (2011)
- [11] Abiodun, O.I., Jantan, A., Omolara, A.E., Dada, K.V., Mohamed, N.A., Arshad, H.: State-of-the-art in artificial neural network applications: A survey. *Heliyon* **4**(11) (2018)

- [12] Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Süsstrunk, S.: SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence* **34**(11), 2274–2282 (2012)
- [13] Agrawal, R., Imieliński, T., Swami, A.: Mining association rules between sets of items in large databases. In: *Proceedings of the 1993 ACM SIGMOD international conference on Management of data*. pp. 207–216 (1993)
- [14] Agrawal, R., Srikant, R., et al.: Fast algorithms for mining association rules. In: *Proc. 20th int. conf. very large data bases, VLDB*. vol. 1215, pp. 487–499. Santiago, Chile (1994)
- [15] Aguilar-Savén, R.S.: Business process modelling: Review and framework. *International Journal of production economics* **90**(2), 129–149 (2004)
- [16] Ahrens, V.: Interpretation des PDCA-Zyklus nach DIN EN ISO 9001: 2015 als Meta-Vorgehensmodell. Tech. rep., Arbeitspapiere der Nordakademie (2016)
- [17] Akiba, T., Sano, S., Yanase, T., Ohta, T., Koyama, M.: Optuna: A next-generation hyperparameter optimization framework. In: *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*. pp. 2623–2631 (2019)
- [18] Alatise, M.B., Hancke, G.P.: A review on challenges of autonomous mobile robot and sensor fusion methods. *IEEE Access* **8**, 39830–39846 (2020)
- [19] Alfred, R.: *Knowledge discovery: Enhancing data mining and decision support integration*. The University of York, United Kingdom (2005)
- [20] Alinaghian, R., Abdul Rahman, A., Ibrahim, R.: Strengthening Business Process Modeling with the Application / Combination of Viable System Model in ICT Policy Analysis Context. *International Journal of Management and Information Technology* **5**, 397–403 (08 2013). doi: 10.24297/ijmit.v5i1.4493
- [21] Almazdi, A.A., Khajah, H.M., Monaco, E.A., Kim, H.: Applying microwave technology to sintering dental zirconia. *The Journal of Prosthetic Dentistry* **108**(5), 304–309 (2012). doi: [https://doi.org/10.1016/S0022-3913\(12\)60181-4](https://doi.org/10.1016/S0022-3913(12)60181-4)
- [22] Altaf, W., Shahbaz, M., Guergachi, A.: Applications of association rule mining in health informatics: a survey. *Artificial Intelligence Review* **47**, 313–340 (2017)
- [23] Alvarez, V.P., Vazquez, J.M.: An evolutionary algorithm to discover quantitative association rules from huge databases without the need for an a priori discretization. *Expert Systems w. Appl.* **39**(1), 585–593 (2012)
- [24] Alzubi, J., Nayyar, A., Kumar, A.: Machine learning from theory to algorithms: an overview. In: *Journal of physics: conference series*. vol. 1142, p. 012012. IOP Publishing (2018)

- [25] Andersen, R.H., Solund, T., Hallam, J.: Definition and initial case-based evaluation of hardware-independent robot skills for industrial robotic co-workers. In: *ISR/Robotik 2014; 41st International Symposium on Robotics*. pp. 1–7. VDE (2014)
- [26] Antoniadi, A.M., Du, Y., Guendouz, Y., Wei, L., Mazo, C., Becker, B.A., Mooney, C.: Current challenges and future opportunities for XAI in machine learning-based clinical decision support systems: a systematic review. *Applied Sciences* **11**(11), 5088 (2021)
- [27] Antoniou, G., Harmelen, F.v.: *Web ontology language: Owl*. Handbook on ontologies pp. 91–110 (2009)
- [28] Avila, D.T., dos Santos, R.I., Mendling, J., Thom, L.H.: A systematic literature review of process modeling guidelines and their empirical support. *Business Process Management Journal* **27**(1), 1–23 (2020)
- [29] Baltagi, B.H.: *Econometric analysis of panel data*, vol. 4. Springer (2008)
- [30] Bänziger, R.B., Basukoski, A., Chausalet, T.: Discovering Business Processes in CRM Systems by Leveraging Unstructured Text Data. In: *2018 IEEE 20th International Conference on High Performance Computing and Communications; IEEE 16th International Conference on Smart City; IEEE 4th International Conference on Data Science and Systems (HPCC/SmartCity/DSS)*. pp. 1571–1577 (2018)
- [31] Barba, I., Weber, B., Del Valle, C.: Supporting the optimized execution of business processes through recommendations. In: *Business Process Management Workshops: BPM 2011 International Workshops, Clermont-Ferrand, France, August 29, 2011, Revised Selected Papers, Part I 9*. pp. 135–140. Springer (2012)
- [32] Batoulis, K., Eid-Sabbagh, R.H., Leopold, H., Weske, M., Mendling, J.: Automatic business process model translation with bpmt. In: *Advanced Information Systems Engineering Workshops: CAiSE 2013 International Workshops, Valencia, Spain, June 17-21, 2013. Proceedings 25*. pp. 217–228. Springer (2013)
- [33] Bayardo, R.J., Agrawal, R., Gunopulos, D.: Constraint-based rule mining in large, dense databases. *Data mining and knowledge discovery* **4**, 217–240 (2000)
- [34] Becker, J., Rosemann, M., Von Uthmann, C.: Guidelines of business process modeling. In: *Business Process Management: Models, Techniques, and Empirical Studies*, pp. 30–49. Springer (2002)
- [35] Bera, P.: Does cognitive overload matter in understanding BPMN models? *Journal of Computer Information Systems* **52**(4), 59–69 (2012)
- [36] Beutelspacher, A., Zschiegner, M.A.: *Boolesche Algebra*, pp. 191–209. Vieweg+Teubner Verlag, Wiesbaden (2002). doi: 10.1007/978-3-322-92922-8_10

- [37] Bizagi: Modern Apps Powered by Process. Modernize your operations with low-code process automation (2023), <https://www.bizagi.com/>, zuletzt besucht: 25.07.2023
- [38] Bobrik, R., Reichert, M., Bauer, T.: Parameterizable Views for Process Visualization. CTIT technical report series (2007)
- [39] Bobrik, R., Reichert, M., Bauer, T.: View-based process visualization. In: Business Process Management: 5th International Conference, BPM 2007, Brisbane, Australia, September 24-28, 2007. Proceedings 5. pp. 88–95. Springer (2007)
- [40] Böhmer, K., Rinderle-Ma, S.: Mining association rules for anomaly detection in dynamic process runtime behavior and explaining the root cause to users. Information Systems **90**, 101438 (2020)
- [41] Bonitasoft: The BPM platform loved by developers, trusted by businesses (2023), <https://www.bonitasoft.com/>, zuletzt besucht: 25.07.2023
- [42] Booch, G.: The unified modeling language user guide. Pearson Education India (2005)
- [43] Brachman, R.J.: The process of knowledge discovery in databases. Advances in knowledge discovery and data mining pp. 37–57 (1996)
- [44] Bradski, G.: The OpenCV Library. Dr. Dobb's Journal of Software Tools (2000)
- [45] Brogårdh, T.: Present and future robot control development - An industrial perspective. Annual Reviews in Control **31**(1), 69–79 (2007)
- [46] Brooke, J., et al.: SUS-A quick and dirty usability scale. Usability evaluation in industry 189, 194 (1996), 4–7. This page intentionally left blank (1996)
- [47] Brosnan, T., Sun, D.W.: Improving quality inspection of food products by computer vision - a review. Journal of food engineering **61**(1), 3–16 (2004)
- [48] Buhmester, V., Münch, D., Arens, M.: Analysis of explainers of black box deep neural networks for computer vision: A survey. Machine Learning and Knowledge Extraction **3**(4), 966–989 (2021)
- [49] Bussler, C.: Organisationsverwaltung in Workflow-Management-Systemen. Dt. Univ. Verl., Jan (1998)
- [50] Cameranesi, M., Diamantini, C., Potena, D.: Discovering process models of activities of daily living from sensors. In: Business Process Management Workshops: BPM 2017 International Workshops, Barcelona, Spain, September 10-11, 2017, Revised Papers 15. pp. 285–297. Springer (2018)
- [51] Camunda: Solve even your most complex automations. (2023), <https://camunda.com/>, zuletzt besucht: 25.07.2023

- [52] Caruana, R., Lou, Y., Gehrke, J., Koch, P., Sturm, M., Elhadad, N.: Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission. In: Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining. pp. 1721–1730 (2015)
- [53] Chen, G., Liu, H., Yu, L., Wei, Q., Zhang, X.: A new approach to classification based on association rule mining. *Decision Support Systems* **42**(2), 674–689 (2006)
- [54] Chinosi, M., Trombetta, A.: BPMN: An introduction to the standard. *Computer Standards & Interfaces* **34**(1), 124–134 (2012)
- [55] Collins, A., Baccarini, D.: Project success - a survey. *Journal of construction research* **5**(02), 211–231 (2004)
- [56] Conforti, R., De Leoni, M., La Rosa, M., Van der Aalst, W.M., Ter Hofstede, A.H.: A recommendation system for predicting risks across multiple business process instances. *Decision Support Systems* **69**, 1–19 (2015)
- [57] Coradeschi, S., Saffiotti, A.: An introduction to the anchoring problem. *Robotics and autonomous systems* **43**(2-3), 85–96 (2003)
- [58] Corradini, F., Ferrari, A., Fornari, F., Gnesi, S., Polini, A., Re, B., Spagnolo, G.O.: A guidelines framework for understandable BPMN models. *Data & Knowledge Engineering* **113**, 129–154 (2018)
- [59] Curtis, B., Kellner, M.I., Over, J.: Process modeling. *Communications of the ACM* **35**(9), 75–90 (1992)
- [60] Darvish, K., Simetti, E., Mastrogiovanni, F., Casalino, G.: A hierarchical architecture for human–robot cooperation processes. *IEEE Transactions on Robotics* **37**(2), 567–586 (2020)
- [61] Davis, D.: AI Unleashes the Power of Unstructured Data, <https://www.cio.com/article/220347/ai-unleashes-the-power-of-unstructured-data.html>, zuletzt besucht: 16.10.2023
- [62] De Weerd, J., Wynn, M.T.: Foundations of Process Event Data, pp. 193–211. Springer International Publishing, Cham (2022). doi: 10.1007/978-3-031-08848-3_6
- [63] Dehghan-Manshadi, A., Yu, P., Dargusch, M., StJohn, D., Qian, M.: Metal injection moulding of surgical tools, biomaterials and medical devices: A review. *Powder Technology* **364**, 189–204 (2020)
- [64] Deming, W.E.: Statistical techniques in industry. *Advanced Management* **18**(11), 8–12 (1953)
- [65] Deshmukh, J., Bhosle, U.: Image mining using association rule for medical image dataset. *Procedia Computer Science* **85**, 117–124 (2016)

- [66] Deshpande, D.S.: Association rule mining based on image content. *International Journal of Information Technology and Knowledge Management* **4**(1), 143–146 (2011)
- [67] Di Stefano, L., Mattoccia, S.: Real-time stereo within the VIDET project. *Real-Time Imaging* **8**(5), 439–453 (2002)
- [68] Donhauser, S.C., Niessner, R., Seidel, M.: Sensitive quantification of *Escherichia coli* O157: H7, *Salmonella enterica*, and *Campylobacter jejuni* by combining stopped polymerase chain reaction with chemiluminescence flow-through DNA microarray analysis. *Analytical Chemistry* **83**(8), 3153–3160 (2011)
- [69] Dumas, M., La Rosa, M., Mendling, J., A Reijers, H.: *Fundamentals of business process management*. Springer (2013)
- [70] Dzindolet, M.T., Peterson, S.A., Pomranky, R.A., Pierce, L.G., Beck, H.P.: The role of trust in automation reliance. *International journal of human-computer studies* **58**(6), 697–718 (2003)
- [71] Eberendu, A.C., et al.: Unstructured Data: an overview of the data of Big Data. *International Journal of Computer Trends and Technology* **38**(1), 46–50 (2016)
- [72] Eccles, D.W., Arsal, G.: The think aloud method: what is it and how do I use it? *Qualitative Research in Sport, Exercise and Health* **9**(4), 514–531 (2017)
- [73] Eilers, K., Nachreiner, F., Hänecke, K.: Entwicklung und Überprüfung einer Skala zur Erfassung subjektiv erlebter Anstrengung. *Zeitschrift für Arbeitswissenschaft* (4), 214–224 (1986)
- [74] Eisenhuth, P., Fichtner, M., Frede, B., Seesemann, R.: Developing Crosslingual Ontologies in WissKI: Transcontinental Research Collaboration in the Africa Multiple Cluster of Excellence. *Modern Languages Open* 2023 (1) (2023). doi: 10.3828/mlo.v0i0.445
- [75] Fahland, D., Favre, C., Koehler, J., Lohmann, N., Völzer, H., Wolf, K.: Analysis on demand: Instantaneous soundness checking of industrial business process models. *Data & Knowledge Engineering* **70**(5), 448–466 (2011)
- [76] Fahland, D., Mendling, J., Reijers, H.A., Weber, B., Weidlich, M., Zugal, S.: Declarative versus imperative process modeling languages: The issue of maintainability. In: *Business Process Management Workshops: BPM 2009 International Workshops*, Ulm, Germany, September 7, 2009. Revised Papers 7. pp. 477–488. Springer (2010)
- [77] Fatma, S.N., Nashipudimath, M.: Image mining using association rule. In: *2011 World Congress on Information and Communication Technologies*. pp. 587–593. IEEE (2011)
- [78] Fayyad, U., Piatetsky-Shapiro, G., Smyth, P.: From data mining to knowledge discovery in databases. *AI magazine* **17**(3), 37–37 (1996)

- [79] Ferguson, M.K., Ronay, A., Lee, Y.T.T., Law, K.H.: Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning. *Smart and sustainable manufacturing systems* **2** (2018)
- [80] Fichtner, M., Fichtner, U.A., Jablonski, S.: An Experimental Study of Intuitive Representations of Process Task Annotations. In: *Cooperative Information Systems: 28th International Conference, CoopIS 2022, Bozen-Bolzano, Italy, October 4–7, 2022, Proceedings*. pp. 311–321. Springer (2022). doi: https://doi.org/10.1007/978-3-031-17834-4_19
- [81] Fichtner, M., Jablonski, S.: A Specification of How to Extract Relevant Process Details to Improve Process Models. In: Filipe, J., Śmiałek, M., Brodsky, A., Hammoudi, S. (eds.) *Enterprise Information Systems*. pp. 391–414. Springer Nature Switzerland, Cham (2023). doi: https://doi.org/10.1007/978-3-031-39386-0_19
- [82] Fichtner, M., Jablonski, S.: Applying Association Rules to Enhance Process Models through the Extraction of Relevant Process Details from Image Data. *Communications of the IBIMA* (172169) (2024). doi: <https://doi.org/10.5171/2024.172169>
- [83] Fichtner, M., Schönig, S., Jablonski, S.: Process Management Enhancement by using Image Mining Techniques: A Position Paper. In: *Proceedings of the 22nd International Conference on Enterprise Information Systems - Volume 1: ICEIS*. pp. 249–255. INSTICC, SciTePress (2020). doi: <https://doi.org/10.5220/0009573502490255>
- [84] Fichtner, M., Schönig, S., Jablonski, S.: Using Image Mining Techniques from a Business Process Perspective. In: Filipe, J., Śmiałek, M., Brodsky, A., Hammoudi, S. (eds.) *Enterprise Information Systems*. pp. 62–83. Springer International Publishing, Cham (2021). doi: https://doi.org/10.1007/978-3-030-75418-1_4
- [85] Fichtner, M., Schönig, S., Jablonski, S.: How LIME Explanation Models Can Be Used to Extend Business Process Models by Relevant Process Details. In: *Proceedings of the 24th International Conference on Enterprise Information Systems - Volume 2: ICEIS*. pp. 527–534. INSTICC, SciTePress (2022). doi: <https://doi.org/10.5220/0011067600003179>
- [86] Fichtner, M., Sucker, S., Riedelbauch, D., Jablonski, S., Henrich, D.: Enriching Process Models with Relevant Process Details for Flexible Human-Robot Teaming. In: Gao, H., Wang, X., Voros, N. (eds.) *Collaborative Computing: Networking, Applications and Worksharing*. pp. 249–269. Springer Nature Switzerland, Cham (2024). doi: https://doi.org/10.1007/978-3-031-54531-3_14
- [87] Fichtner, U.A., Piotrowsky-Fichtner, M., Fichtner, M., Goßmann, A.K., Weis, F., Weiß, M., Steinmann, D.: Entwicklung konkreter Handlungsoptionen für die sichere Öffnung und den Betrieb von Freizeitdestinationen unter Pandemiebedingungen. *Zentralblatt für Arbeitsmedizin, Arbeitsschutz und Ergonomie* **72**(6), 267–277 (2022)

- [88] Figl, K.: Comprehension of procedural visual business process models: a literature review. *Business & Information Systems Engineering* **59**, 41–67 (2017)
- [89] Figl, K., Mendling, J., Strembeck, M.: Towards a usability assessment of process modeling languages. In: 8th GI-Workshop Geschäftsprozessmanagement mit Ereignisgesteuerten Prozessketten (EPK), CEUR-WS. vol. 554, pp. 138–156. Cite-seer (2009)
- [90] Figl, K., Recker, J.: Exploring cognitive style and task-specific preferences for process representations. *Requirements Engineering* **21**, 63–85 (2016)
- [91] Figl, K., Recker, J.: Process innovation as creative problem solving: An experimental study of textual descriptions and diagrams. *Information & Management* **53**(6), 767–786 (2016)
- [92] Foote, D.A., Folta, T.B.: Temporary workers as real options. *Human Resource Management Review* **12**(4), 579–597 (2002)
- [93] Füßl, A., Nissen, V., Heringklee, S.H.: Knowledge Graph-Based Explainable Artificial Intelligence for Business Process Analysis. *International Journal of Semantic Computing* **17**(02), 173–197 (2023)
- [94] Gadatsch, A.: *Grundkurs geschäftsprozess-management*. Springer (2010)
- [95] Gelman, A., Hill, J.: *Data analysis using regression and multilevel/hierarchical models*. Cambridge university press (2006)
- [96] Gemino, A., Parker, D.: Use case diagrams in support of use case modeling: Deriving understanding from the picture. *Journal of Database Management (JDM)* **20**(1), 1–24 (2009)
- [97] Gemino, A., Wand, Y.: A framework for empirical evaluation of conceptual modeling techniques. *Requirements Engineering* **9**, 248–260 (2004)
- [98] Gericke, A., Bayer, F., Kühn, H., Rausch, T., Strobl, R.: Der Lebenszyklus des Prozessmanagements. *Prozessmanagement für Experten: Impulse für aktuelle und wiederkehrende Themen* pp. 11–33 (2013)
- [99] Ghasemi, M., Amyot, D.: Process mining in healthcare: a systematised literature review. *International Journal of Electronic Healthcare* **9**(1), 60–88 (2016)
- [100] Goel, R., Gupta, P.: Robotics and industry 4.0. *A Roadmap to Industry 4.0: Smart Production, Sharp Business and Sustainable Development* pp. 157–169 (2020)
- [101] Gorecky, D., Weyer, S., Hennecke, A., Zühlke, D.: Design and Instantiation of a Modular System Architecture for Smart Factories. *IFAC-PapersOnLine* **49**(31), 79–84 (2016). doi: <https://doi.org/10.1016/j.ifacol.2016.12.165>, 12th IFAC Workshop on Intelligent Manufacturing Systems IMS 2016

- [102] Guidotti, R., Monreale, A., Ruggieri, S., Pedreschi, D., Turini, F., Giannotti, F.: Local rule-based explanations of black box decision systems. arXiv preprint arXiv:1805.10820 (2018)
- [103] Gunther, C.W., Verbeek, H.: Xes-standard definition (2014)
- [104] Günther, L.C., Kärcher, S., Bauernhansl, T.: Activity recognition in manual manufacturing: Detecting screwing processes from sensor data. *Procedia CIRP* **81**, 1177–1182 (2019)
- [105] Güzler, F.: Assetmanagement in elektrischen Netzen–nachhaltig in Balance. In: *Infrastrukturen leitungsgebundener Energieträger* (2021)
- [106] Gupta, N., Anand, K., Sureka, A.: Pariket: Mining business process logs for root cause analysis of anomalous incidents. In: *Databases in Networked Information Systems: 10th International Workshop, DNIS 2015, Aizu-Wakamatsu, Japan, March 23-25, 2015. Proceedings 10*. pp. 244–263. Springer (2015)
- [107] Gurney, K.: *An introduction to neural networks*. CRC press (1997)
- [108] Han, J., Kamber, M., Pei, J.: *Data mining concepts and techniques third edition*. University of Illinois at Urbana-Champaign Micheline Kamber Jian Pei Simon Fraser University (2012)
- [109] Han, J., Pei, J., Yin, Y.: Mining frequent patterns without candidate generation. *ACM sigmod record* **29**(2), 1–12 (2000)
- [110] Harmon, P., Wolf, C.: *The state of business process management*. BP Trends (2016)
- [111] Hasegawa, T., Suehiro, T., Takase, K.: A model-based manipulation system with skill-based execution. *IEEE Trans. on Robotics and Autom.* **8**(5), 535–544 (1992)
- [112] Havey, M.: *Essential business process modeling*. Ö'Reilly Media, Inc."(2005)
- [113] Hegge, H.M., Wortmann, J.: Generic bill-of-material: a new product model. *International Journal of Production Economics* **23**(1-3), 117–128 (1991)
- [114] Hevner, A.R., March, S.T., Park, J., Ram, S.: Design Science in Information Systems Research. *MIS Quarterly* **28**(1), 75–105 (2004)
- [115] Hijazi, S., Kumar, R., Rowen, C., et al.: Using convolutional neural networks for image recognition. Cadence Design Systems Inc.: San Jose, CA, USA **9**(1) (2015)
- [116] Hipp, J., Güntzer, U., Nakhaeizadeh, G.: Algorithms for association rule mining - a general survey and comparison. *ACM sigkdd explorations newsletter* **2**(1), 58–64 (2000)
- [117] Holzinger, A.: Explainable AI (ex-AI). *Informatik-Spektrum* **41**, 138–143 (2018)

- [118] Houy, C., Fettke, P., Loos, P.: On the Theoretical Foundations of Research into the Understandability of Business Process Models. In: European Conference on Information Systems (2014)
- [119] Huisl, J., Fichtner, M., Eisenhuth, P., Baumann, O., Schönfeld, M., Jablonski, S., Samimi, C.: Towards an Integrated and Contextualized Research Data Management at the Cluster of Excellence Africa Multiple. University of Bayreuth African Studies Online **9**, 155–172 (2022)
- [120] Hurtienne, J., Dinsel, C., Sturm, C.: QUESI–design and evaluation of a questionnaire for the subjective consequences of intuitive use. Unpublished manuscript, Fachgebiet MenschYMaschine Systeme, Technische Universität Berlin (2009)
- [121] Hurtienne, J., et al.: Image schemas and design for intuitive use. Ph.D. thesis, Technische Universität Berlin (2009)
- [122] Ibrahim, M., Louie, M., Modarres, C., Paisley, J.: Global explanations of neural networks: Mapping the landscape of predictions. In: Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society. pp. 279–287 (2019)
- [123] Imtiaz, S., Ikram, N., Imtiaz, S.: A process model for managing requirement change. In: Proceedings of the Fourth IASTED Int. Conference on Advances in Computer Science and Technology. ACTA Press, Langkawi, Malaysia (2008)
- [124] ISO/IEC 19510:2013: Information technology - Object Management Group Business Process Model and Notation (2023), <https://www.iso.org/standard/62652.html>, zuletzt besucht: 12.08.2023
- [125] Jablonski, S.: Prozessdesign und -modellierung für ein holistisches Prozessmanagement. In: Anwendungsinformatik. Die Zukunft des Enterprise Engineering. pp. 83–105. Nomos Verlagsgesellschaft mbH & Co. KG (2009)
- [126] Jablonski, S., Bussler, C.: MOBILE: A modular workflow model and architecture. In: Working Conference on Dynamic Modelling and Information Systems (1994)
- [127] Jablonski, S., Bussler, C.: Workflow management: modeling concepts, architecture and implementation. ITP New Media (1996)
- [128] Jaeger, T., Prakash, A., Ishikawa, M.: A framework for automatic improvement of workflows to meet performance goals. In: Proceedings Sixth International Conference on Tools with Artificial Intelligence. TAI 94. pp. 640–646. IEEE (1994)
- [129] Joens, C.: Laminar gas flows ensure 'clean sweep' in sintering. Metal Powder Report **60**(3), 52–55 (2005)
- [130] Jordon, J., Szpruch, L., Houssiau, F., Bottarelli, M., Cherubin, G., Maple, C., Cohen, S.N., Weller, A.: Synthetic Data–what, why and how? arXiv preprint arXiv:2205.03257 (2022)

- [131] Jošt, G., Huber, J., Heričko, M., Polančič, G.: An empirical investigation of intuitive understandability of process diagrams. *Computer Standards & Interfaces* **48**, 90–111 (2016)
- [132] Kaiser, S., Reichert, M.: *Datenflussvarianten in Prozessmodellen: Szenarien, Herausforderungen, Ansätze*. Universität Ulm (2011)
- [133] Kasabov, N.K.: *Foundations of neural networks, fuzzy systems, and knowledge engineering*. Marcel Alencar (1996)
- [134] Kellner, M.I.: *Software process modeling: value and experience*. Carnegie Mellon University, Software Engineering Institute (1989)
- [135] Keselman, H., Rogan, J.C.: The Tukey multiple comparison test: 1953–1976. *Psychological Bulletin* **84**(5), 1050 (1977)
- [136] Klein, K., Franke, M., Hribernik, K.A., Thoben, K.D.: Identification of interface information for a virtual data integration. In: *Enterprise Interoperability VI: Interoperability for Agility, Resilience and Plasticity of Collaborations*. pp. 89–99. Springer (2014)
- [137] Knoch, S., Herbig, N., Ponpathirkoottam, S., Kosmalla, F., Staudt, P., Fettke, P., Loos, P.: Enhancing process data in manual assembly workflows. In: *Business Process Management Workshops: BPM 2018 International Workshops, Sydney, NSW, Australia, September 9-14, 2018, Revised Papers 16*. pp. 269–280. Springer (2019)
- [138] Knoch, S., Ponpathirkoottam, S., Fettke, P., Loos, P.: Technology-enhanced process elicitation of worker activities in manufacturing. In: *Business Process Management Workshops: BPM 2017 International Workshops, Barcelona, Spain, September 10-11, 2017, Revised Papers 15*. pp. 273–284. Springer (2018)
- [139] Knoch, S., Ponpathirkoottam, S., Schwartz, T.: Video-to-model: Unsupervised trace extraction from videos for process discovery and conformance checking in manual assembly. In: *Business Process Management: 18th International Conference, BPM 2020, Seville, Spain, September 13–18, 2020, Proceedings 18*. pp. 291–308. Springer (2020)
- [140] Kok, J.N., Boers, E.J., Kusters, W.A., Van der Putten, P., Poel, M.: Artificial intelligence: definition, trends, techniques, and cases. *Artificial intelligence* **1**, 270–299 (2009)
- [141] Kopp, A., Orlovskiy, D.: *Business process model optimization using the conjugate gradient method* (2019)
- [142] Koschmider, A., Caporale, T., Fellmann, M., Lehner, J., Oberweis, A.: Business process modeling support by depictive and descriptive diagrams. In: *6th International Workshop on Enterprise Modelling and Information Systems Architectures (EMISA), Innsbruck, Austria, 3-4 September 2015*. Ed.: J. Kolb. GI-Edition / Proceedings, vol. 248, pp. 31–44. Ges. für Informatik (2015)

- [143] Kotsiantis, S., Kanellopoulos, D.: Association rules mining: A recent overview. *GESTS International Transactions on Computer Science and Engineering* **32**(1), 71–82 (2006)
- [144] Kotsiantis, S., Kanellopoulos, D.: Discretization techniques: A recent survey. *GESTS International Transactions on Computer Science and Engineering* **32**(1), 47–58 (2006)
- [145] Kratsch, W., König, F., Röglinger, M.: Shedding light on blind spots—developing a reference architecture to leverage video data for process mining. *Decision Support Systems* **158**, 113794 (2022)
- [146] Krogh, A.: What are artificial neural networks? *Nature biotechnology* **26**(2), 195–197 (2008)
- [147] Krogstie, J.: Quality of business process models. In: *IFIP Working Conference on The Practice of Enterprise Modeling*. pp. 76–90. Springer (2012)
- [148] Kuksa, I., Fisher, T.: *Design for personalisation*. Taylor & Francis (2017)
- [149] Kumbhare, T.A., Chobe, S.V.: An overview of association rule mining algorithms. *International Journal of Computer Science and Information Technologies* **5**(1), 927–930 (2014)
- [150] Lakkaraju, H., Kamar, E., Caruana, R., Leskovec, J.: Interpretable & explorable approximations of black box models. *arXiv preprint arXiv:1707.01154* (2017)
- [151] Lee, A.S., Baskerville, R.L.: Generalizing generalizability in information systems research. *Information systems research* **14**(3), 221–243 (2003)
- [152] Lee, D.E., Hwang, I., Valente, C.M., Oliveira, J.F.G.d., Dornfeld, D.A.: *Precision manufacturing process monitoring with acoustic emission*. Springer (2006)
- [153] Letham, B., Rudin, C., McCormick, T.H., Madigan, D.: Interpretable classifiers using rules and Bayesian analysis: Building a better stroke prediction model. *The Annals of Applied Statistics* **9**(3), 1350 – 1371 (2015). doi: 10.1214/15-AOAS848
- [154] Leymann, F., Roller, D.: *Production workflow: concepts and techniques*. Prentice Hall PTR (1999)
- [155] Link, M.: *Zweistufiger Modellierungsansatz zum nachhaltigen Prozessmanagement*. Tech. rep., Darmstadt Technical University, Department of Business Administration (2010)
- [156] Luna, J.M., Ondra, M., Fardoun, H.M., Ventura, S.: Optimization of quality measures in association rule mining: an empirical study. *International Journal of Computational Intelligence Systems* **12**(1), 59–78 (2018)
- [157] Lundberg, S.M., Lee, S.I.: A unified approach to interpreting model predictions. *Advances in neural information processing systems* **30** (2017)

- [158] Madni, H.A., Anwar, Z., Shah, M.A.: Data mining techniques and applications — A decade review. In: 2017 23rd International Conference on Automation and Computing (ICAC). pp. 1–7 (2017). doi: 10.23919/ICoAC.2017.8082090
- [159] Maeyens, J., Vorstermans, A., Verbeke, M.: Process mining on machine event logs for profiling abnormal behaviour and root cause analysis. *Annals of Telecommunications* **75**(9-10), 563–572 (2020)
- [160] Maita, A.R.C., Fantinato, M., Peres, S.M., Maggi, F.M.: Towards a Business-Oriented Approach to Visualization-Supported Interpretability of Prediction Results in Process Mining. In: ICEIS (1). pp. 395–406 (2023)
- [161] Mannhardt, F.: Multi-perspective process mining. Ph.D. thesis, Technische Universiteit Eindhoven (2018)
- [162] Mannhardt, F., Bovo, R., Oliveira, M.F., Julier, S.: A taxonomy for combining activity recognition and process discovery in industrial environments. In: International Conference on Intelligent Data Engineering and Automated Learning. pp. 84–93. Springer (2018)
- [163] Mansuri, I.R., Sarawagi, S.: Integrating Unstructured Data into Relational Databases. In: 22nd International Conference on Data Engineering (ICDE'06). pp. 29–29 (2006). doi: 10.1109/ICDE.2006.83
- [164] March, S.T., Storey, V.C.: Design science in the information systems discipline: an introduction to the special issue on design science research. *MIS quarterly* pp. 725–730 (2008)
- [165] Marr, B.: What Is Unstructured Data And Why Is It So Important To Businesses? An Easy Explanation For Anyone, <https://www.forbes.com/sites/bernardmarr/2019/10/16/what-is-unstructured-data-and-why-is-it-so-important-to-businesses-an-easy-explanation-for-anyone/?sh=75762cb515f6>, zuletzt besucht: 16.10.2023
- [166] Mathiesen, P., Watson, J., Bandara, W., Rosemann, M.: Applying social technology to business process lifecycle management. In: Business Process Management Workshops: BPM 2011 International Workshops, Clermont-Ferrand, France, August 29, 2011, Revised Selected Papers, Part I 9. pp. 231–241. Springer (2012)
- [167] Maveli, N.: Demystifying Post-hoc Explainability for ML models, <https://spectra.mathpix.com/article/2021.09.00007/demystify-post-hoc-explainability>, zuletzt besucht: 23.10.2023
- [168] Mendling, J., Reijers, H.A., van der Aalst, W.M.: Seven process modeling guidelines (7PMG). *Information and software technology* **52**(2), 127–136 (2010)
- [169] Mendling, J., Reijers, H.A., Cardoso, J.: What makes process models understandable? In: Business Process Management: 5th International Conference, BPM 2007, Brisbane, Australia, September 24-28, 2007. Proceedings 5. pp. 48–63. Springer (2007)

- [170] Mevius, M.: Kennzahlenbasiertes Management von Geschäftsprozessen mit Petri-Netzen. Ph.D. thesis, Karlsruher Institut für Technologie (2006)
- [171] Meyer, A.: Data perspective in business process management: the role of data for process modeling, analysis, and execution. Ph.D. thesis, Universität Potsdam (2015)
- [172] Michaelis, J.: Erzeugung von Aufgabenbeschreibungen aus Prozessdetails. Bachelor's thesis, Universität Bayreuth (2022)
- [173] Miller, R.B.: Human ease of use criteria and their tradeoffs. IBM, Systems Development Division, Poughkeepsie Lab (1971)
- [174] Mohs, C., Hurtienne, J., Kindsmüller, M.C., Israel, J.H., Meyer, H.A., et al.: IUUI–Intuitive Use of User Interfaces: Auf dem Weg zu einer wissenschaftlichen Basis für das Schlagwort „Intuitivität“. *MMI-Interaktiv* **11**(11), 75–84 (2006)
- [175] Munkres, J.: Algorithms for the assignment and transportation problems. *Journal of the society for industrial and applied mathematics* **5**(1), 32–38 (1957)
- [176] Mur-Artal, R., Tardós, J.D.: Orb-slam2: An open-source slam system for monocular, stereo, and rgb-d cameras. *IEEE transactions on robotics* **33**(5), 1255–1262 (2017)
- [177] Nakagawa, S., Johnson, P.C., Schielzeth, H.: The coefficient of determination R^2 and intra-class correlation coefficient from generalized linear mixed-effects models revisited and expanded. *Journal of the Royal Society Interface* **14**(134), 20170213 (2017)
- [178] Naumann, A., Hurtienne, J.: Benchmarks for intuitive interaction with mobile devices. In: *Proceedings of the 12th international conference on Human computer interaction with mobile devices and services*. pp. 401–402 (2010)
- [179] Neuerburg, C.: Lerntypen und ihre Bedeutung für die Praxis der Personalentwicklung. diplom. de (2006)
- [180] Niedermann, F., Radeschütz, S., Mitschang, B.: Deep business optimization: A platform for automated process optimization. In: *INFORMATIK 2010 – Business Process and Service Science – Proceedings of ISSS and BPSC*. Gesellschaft für Informatik e.V. (2010)
- [181] Nielsen, J., et al.: Usability 101: Introduction to usability (2012), <https://www.nngroup.com/articles/usability-101-introduction-to-usability/>, zuletzt besucht: 05.12.2023
- [182] Nissen, M.E.: An intelligent tool for process redesign: manufacturing supply-chain applications. *Int. Journal of Flexible Manufacturing Systems* **12**, 321–339 (2000)

- [183] Niu, X., Ding, H., Xiong, Y.: A hierarchical approach to generating precedence graphs for assembly planning. *International Journal of Machine Tools and Manufacture* **43**(14), 1473–1486 (2003)
- [184] Nottensteiner, K., et al.: A complete automated chain for flexible assembly using recognition, planning and sensor-based execution. In: *Proc. of 47st Intern. Symp. on Robotics (ISR)*. pp. 1–8 (2016)
- [185] Object Management Group (OMG): <http://www.omg.org/>, zuletzt besucht: 12.08.2023
- [186] Object Management Group (OMG): Business Process Model and Notation (BPMN), <https://www.omg.org/spec/BPMN/2.0.2/PDF>, zuletzt besucht: 17.08.2023
- [187] Moreno-Montes de Oca, I., Snoeck, M.: Pragmatic guidelines for business process modeling. Available at SSRN 2592983 (2014)
- [188] Orendt, E.M., Fichtner, M., Henrich, D.: Robot programming by non-experts: Intuitiveness and robustness of one-shot robot programming. In: *2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. pp. 192–199. IEEE (2016)
- [189] Orendt, E.M., Fichtner, M., Henrich, D.: MINERIC toolkit: Measuring instruments to evaluate robustness and intuitiveness of robot programming concepts. In: *2017 26th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. pp. 1379–1386. IEEE (2017)
- [190] Osterweil, L.: Software processes are software too. In: *Engineering of Software: The Continuing Contributions of Leon J. Osterweil*, pp. 323–344. Springer (2011)
- [191] Ottensooser, A., Fekete, A., Reijers, H.A., Mendling, J., Menictas, C.: Making sense of business process descriptions: An experimental comparison of graphical and textual notations. *Journal of Systems and Software* **85**(3), 596–606 (2012), novel approaches in the design and implementation of systems/software architecture
- [192] Padella, A., de Leoni, M., Dogan, O., Galanti, R.: Explainable process prescriptive analytics. In: *2022 4th International Conference on Process Mining (ICPM)*. pp. 16–23. IEEE (2022)
- [193] Patel, D., Patel, B., Patel, H., Patel, C.: Design of controlled release non-erodible polymeric matrix tablet using microwave oven-assisted sintering technique. *Journal of Young Pharmacists* **3**(3), 176–180 (2011)
- [194] Patig, S., Casanova-Brito, V.: Requirements of Process Modeling Languages-Results from an Empirical Investigation. In: *Wirtschaftsinformatik Proceedings 2011*. 39. (2011)

- [195] Paxton, C., Hundt, A., Jonathan, F., Guerin, K., Hager, G.D.: CoSTAR: Instructing collaborative robots with behavior trees and vision. In: 2017 IEEE international conference on robotics and automation (ICRA). pp. 564–571. IEEE (2017)
- [196] Pedersen, M.R., Nalpantidis, L., Andersen, R.S., Schou, C., Bøgh, S., Krüger, V., Madsen, O.: Robot skills for manufacturing: From concept to industrial deployment. *Robotics and Computer-Integrated Manufacturing* **37**, 282–291 (2016)
- [197] Peffers, K., Tuunanen, T., Rothenberger, M.A., Chatterjee, S.: A design science research methodology for information systems research. *Journal of management information systems* **24**(3), 45–77 (2007)
- [198] Pereira, J.L., Silva, D.: Business process modeling languages: A comparative framework. In: *New Advances in Information Systems and Technologies*. pp. 619–628. Springer (2016)
- [199] Pesic, M.: Constraint-based workflow management systems: shifting control to users. Ph.D. thesis, Technische Universiteit Eindhoven, Nederland (2008)
- [200] Petter, S., Fichtner, M., Jablonski, S.: Considering User Preferences During Business Process Execution Using Content-Based Filtering. In: Filipe, J., Śmiałek, M., Brodsky, A., Hammoudi, S. (eds.) *Enterprise Information Systems*. pp. 415–429. Springer Nature Switzerland, Cham (2023)
- [201] Petter, S., Fichtner, M., Schöning, S., Jablonski, S.: Content-based Filtering for Worklist Reordering to improve User Satisfaction: A Position Paper. In: *Proceedings of the 24th International Conference on Enterprise Information Systems - Volume 2: ICEIS*. pp. 589–596. INSTICC, SciTePress (2022)
- [202] Polpinij, J., Ghose, A.K., Dam, H.K.: Business rules discovery from process design repositories. In: 2010 6th World Congress on Services. pp. 614–620. IEEE (2010)
- [203] Polyvyanyy, A., Smirnov, S., Weske, M.: Process model abstraction: A slider approach. In: 2008 12th International IEEE Enterprise Distributed Object Computing Conference. pp. 325–331. IEEE (2008)
- [204] Pospiech, S., Mertens, R., Mielke, S., Städler, M., Söhlke, P.: Creating event logs from heterogeneous, unstructured business data. In: *Multidimensional Views on Enterprise Information Systems: Proceedings of ERP Future 2014*. pp. 85–93. Springer (2016)
- [205] Pospiech, S., Mielke, S., Mertens, R., Pelke, M., Jagannath, K., Stadler, M.: Exploration and analysis of undocumented processes using heterogeneous and unstructured business data. In: 2014 IEEE International Conference on Semantic Computing. pp. 191–198. IEEE (2014)
- [206] Prykäri, T., Czajkowski, J., Alarousu, E., Myllylä, R.: Optical coherence tomography as an accurate inspection and quality evaluation technique in paper industry. *Optical review* **17**, 218–222 (2010)

- [207] Qafari, M.S., van der Aalst, W.: Root cause analysis in process mining using structural equation models. In: Business Process Management Workshops: BPM 2020 International Workshops, Seville, Spain, September 13–18, 2020, Revised Selected Papers 18. pp. 155–167. Springer (2020)
- [208] Qi, C.c.: Big data management in the mining industry. *International Journal of Minerals, Metallurgy and Materials* **27**, 131–139 (2020)
- [209] Radečić, D.: LIME vs. SHAP: Which is Better for Explaining Machine Learning Models? Two of the most popular Explainers compared, <https://towardsdatascience.com/lime-vs-shap-which-is-better-for-explaining-machine-learning-models-d68d8290bb16>, zuletzt besucht: 24.10.2023
- [210] Ramzan, S., Ikram, N.: Requirement change management process models: activities, artifacts and roles. In: 2006 IEEE International Multitopic Conference. pp. 219–223. IEEE (2006)
- [211] Raso, R., Emrich, A., Burghardt, T., Schlenker, M., Gudehus, T., Sträter, O., Fettke, P., Loos, P.: Activity Monitoring Using Wearable Sensors in Manual Production Processes—An Application of CPS for Automated Ergonomic Assessments (2018)
- [212] Rawat, W., Wang, Z.: Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation* **29**(9), 2352–2449 (2017)
- [213] Rayner, A.: Knowledge Discovery: Enhancing Data Mining and Decision Support Integration. Ph.D. thesis, The University of York, United Kingdom (2005)
- [214] Recker, J.: Opportunities and constraints: the current struggle with BPMN. *Business Process Management Journal* **16**(1), 181–201 (2010)
- [215] Reichert, M., Kolb, J., Bobrik, R., Bauer, T.: Enabling personalized visualization of large business processes through parameterizable views. In: Proceedings of the 27th Annual ACM Symposium on Applied Computing. pp. 1653–1660 (2012)
- [216] Reichert, M., Weber, B.: Enabling flexibility in process-aware information systems: challenges, methods, technologies, vol. 54. Springer (2012)
- [217] Reijers, H.A.: Design and control of workflow processes: business process management for the service industry, vol. 2617. Springer (2003)
- [218] Reiter, E., Dale, R.: Building applied natural language generation systems. *Natural Language Engineering* **3**(1), 57–87 (1997)
- [219] Anycubic: The moment you’ve all been waiting for: 4Max Metal is here. (2020), <https://www.youtube.com/watch?v=QaMdjKE7vT8>, zuletzt besucht: 17.10.2023
- [220] Coalition, TWM: Terminology & glossary (Issues 3.0). Workflow Management Coalition, Winchester, UK, WPMC-TC-1011 (1999)

- [221] Formatec. A NanoDimension Division.: Metallspritzguss (2020), <https://formateceurope.com/de/metallspritzguss>, zuletzt besucht: 17.10.2023
- [222] R Project: The R Project for Statistical Computing (2024), <https://www.r-project.org/>, zuletzt besucht: 21.02.2024
- [223] Ribeiro, M.T., Singh, S., Guestrin, C.: "Why should i trust you? Explaining the predictions of any classifier. In: Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. pp. 1135–1144 (2016)
- [224] Riedelbauch, D., Henrich, D.: Fast graphical task modelling for flexible human-robot teaming. In: ISR 2018; 50th International Symposium on Robotics. pp. 1–6. VDE (2018)
- [225] Riedelbauch, D., Hümmer, J.: A Benchmark Toolkit for Collaborative Human-Robot Interaction. In: 2022 31st IEEE International Conference on Robot and Human Interactive Communication (RO-MAN). pp. 806–813. IEEE (2022)
- [226] Riedelbauch, D., Sucker, S.: Visual Programming of Robot Tasks with Product and Process Variety. In: MHI Colloquium. pp. 241–252. Springer International Publishing Cham (2022)
- [227] Rinderle-Ma, S., Stertz, F., Mangler, J., Pauker, F.: Process Mining—Discovery, Conformance, and Enhancement of Manufacturing Processes. In: Digital Transformation: Core Technologies and Emerging Topics from a Computer Science Perspective, pp. 363–383. Springer (2023)
- [228] Rodrigues, R.D.A., Barros, M.D.O., Revoredo, K., Azevedo, L.G., Leopold, H.: An experiment on process model understandability using textual work instructions and BPMN models. In: 2015 29th Brazilian Symposium on Software Engineering. pp. 41–50. IEEE (2015)
- [229] Rohner, D., Fichtner, M., Henrich, D.: Vision-based Generation of Precedence Graphs. In: Tagungsband des 4. Kongresses Montage Handhabung Industrieroboter. pp. 13–22. Springer (2019)
- [230] Sanchez-Segura, M.I., González-Cruz, R., Medina-Dominguez, F., Dugarte-Peña, G.L.: Valuable Business Knowledge Asset Discovery by Processing Unstructured Data. *Sustainability* **14**(20), 12971 (2022)
- [231] Garcia dos Santos, C., Meinheim, A., Ribeiro, E.F., Dallagassa, M.R., Sato, D.M.V., Carvalho, D.R., Santos, E.A.P., Scalabrin, E.E.: Process mining techniques and applications – A systematic mapping study. *Expert Systems with Applications* **133**, 260–295 (2019)
- [232] Sathish, T., Chandramohan, D., Vijayan, V., Sebastian, P.: Investigation on microstructural and mechanical properties of Cu reinforced with Sic composites prepared by microwave sintering process. *Journal of New Materials for Electrochemical Systems* **22**(1), 5–9 (2019)

- [233] Satterthwaite, F.E.: Synthesis of variance. *Psychometrika* **6**(5), 309–316 (1941)
- [234] Scheer, A.W.: Nutzentreiber der Digitalisierung: Ein systematischer Ansatz zur Entwicklung disruptiver digitaler Geschäftsmodelle. *Informatik-Spektrum* **39**(4), 275–289 (2016)
- [235] Scheer, A.W., Thomas, O., Adam, O.: Process modeling using event-driven process chains. *Process-Aware Information Systems: Bridging People and Software through Process Technology* pp. 119–145 (2005)
- [236] Schmidt, R., Möhring, M., Zimmermann, A., Härting, R.C., Keller, B.: Potentials of image mining for business process management. In: *Intelligent Decision Technologies 2016*, pp. 429–440. Springer (2016)
- [237] Schönig, S.: Ein Process Mining-Rahmenwerk für agile, personenbezogene Prozesse. *Universitaet Bayreuth (Germany)* (2015)
- [238] Schönig, S., Günther, C., Zeising, M., Jablonski, S.: Discovering Cross-Perspective Semantic Definitions from Process Execution Logs. *BUSTECH 2012* p. 8 (2012)
- [239] Schützenmeier, N., Jablonski, S., Schönig, S.: Towards a Hybrid Process Modeling Language. In: *International Conference on Research Challenges in Information Science*. pp. 630–636. Springer (2021)
- [240] Schützenmeier, N., Käppel, M., Fichtner, M., Jablonski, S.: Scenario-Based Model Checking of Declarative Process Models. In: *Proceedings of the 25th International Conference on Enterprise Information Systems - Volume 2: ICEIS*. pp. 406–417. INSTICC, SciTePress (2023)
- [241] Sehrawat, D., Gill, N.S.: Smart sensors: Analysis of different types of IoT sensors. In: *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*. pp. 523–528. IEEE (2019)
- [242] Selic, B., et al.: *Omg unified modeling language (version 2.5)*. Tech. Rep. (2015)
- [243] Senft, E., Hagenow, M., Radwin, R., Zinn, M., Gleicher, M., Mutlu, B.: Situated live programming for human-robot collaboration. In: *The 34th Annual ACM Symposium on User Interface Software and Technology*. pp. 613–625 (2021)
- [244] Shackel, B.: Usability–Context, framework, definition, design and evaluation. *Interacting with computers* **21**(5-6), 339–346 (2009)
- [245] Shang, H., Lu, D., Zhou, Q.: Early warning of enterprise finance risk of big data mining in internet of things based on fuzzy association rules. *Neural Computing and Applications* **33**, 3901–3909 (2021)
- [246] Shinde, P.P., Shah, S.: A review of machine learning and deep learning applications. In: *2018 Fourth international conference on computing communication control and automation (ICCUBEA)*. pp. 1–6. IEEE (2018)

- [247] Shorten, C., Khoshgoftaar, T.M.: A survey on image data augmentation for deep learning. *Journal of big data* **6**(1), 1–48 (2019)
- [248] Singh, K.K., Singh, A.: A study of image segmentation algorithms for different types of images. *International Journal of Computer Science Issues (IJCSI)* **7**(5), 414 (2010)
- [249] Slaats, T., Schunselaar, D.M., Maggi, F.M., Reijers, H.A.: The semantics of hybrid process models. In: *OTM Confederated International Conferences 'On the Move to Meaningful Internet Systems'*. pp. 531–551. Springer (2016)
- [250] Smiley, S.: Factoring in the Environment: RFID Deployments, <https://www.atlasrfidstore.com/rfid-insider/factoring-environment-rfid-deployments>, zuletzt besucht: 16.10.2023
- [251] Smirnov, S., Reijers, H.A., Weske, M., Nugteren, T.: Business process model abstraction: a definition, catalog, and survey. *Distributed and Parallel Databases* **30**, 63–99 (2012)
- [252] Smith, J.R., Fishkin, K.P., Jiang, B., Mamishev, A., Philipose, M., Rea, A.D., Roy, S., Sundara-Rajan, K.: RFID-based techniques for human-activity detection. *Communications of the ACM* **48**(9), 39–44 (2005)
- [253] Soliman, F.: Optimum level of process mapping and least cost business process re-engineering. *International Journal of Operations & Production Management* **18**(9/10), 810–816 (1998)
- [254] Srikant, R., Agrawal, R.: Mining quantitative association rules in large relational tables. In: *Proceedings of the 1996 ACM SIGMOD*. pp. 1–12 (1996)
- [255] Stachowiak, H.: *Allgemeine Modelltheorie*. Springer, Wien ; New York (1973)
- [256] Steinmetz, F., Wollschläger, A., Weitschat, R.: Razer—a hri for visual task-level programming and intuitive skill parameterization. *IEEE Robotics and Automation Letters* **3**(3), 1362–1369 (2018)
- [257] Stevens, A., De Smedt, J.: Explainability in process outcome prediction: Guidelines to obtain interpretable and faithful models. *European Journal of Operational Research* (2023)
- [258] Stiefmeier, T., Roggen, D., Ogris, G., Lukowicz, P., Tröster, G.: Wearable Activity Tracking in Car Manufacturing. *IEEE Pervasive Computing* **7**(2), 42–50 (2008). doi: 10.1109/MPRV.2008.40
- [259] Strossa, P., Rauch, J.: Converting Association Rules into Natural Language—An Attempt. In: *Intelligent Information Processing and Web Mining: Proceedings of the International IIS: IIPWM'03 Conference held in Zakopane, Poland, June 2–5, 2003*. pp. 383–392. Springer (2003)

- [260] Sturm, C., Fichtner, M., Schönig, S.: Full support for efficiently mining multi-perspective declarative constraints from process logs. *Information* **10**(1), 29 (2019)
- [261] Suriadi, S., Ouyang, C., van der Aalst, W.M., ter Hofstede, A.H.: Root cause analysis with enriched process logs. In: *Business Process Management Workshops: BPM 2012 International Workshops*, Tallinn, Estonia, September 3, 2012. Revised Papers 10. pp. 174–186. Springer (2013)
- [262] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.: Going deeper with convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 1–9 (2015)
- [263] Szeliski, R.: *Computer vision: algorithms and applications*. Springer Nature (2022)
- [264] Tarkkanen, K.: Business process modeling for non-uniform work. In: *Enterprise Information Systems: 10th International Conference, ICEIS 2008, Barcelona, Spain, June 12-16, 2008, Revised Selected Papers 10*. pp. 188–200. Springer (2009)
- [265] Thabet, D., Ayachi Ghannouchi, S., Hajjami Ben Ghezala, H.: A process mining-based solution for business process model extension with cost perspective context-based cost data analysis and case study. In: *Computer Information Systems and Industrial Management: 17th Int. Conference, CISIM 2018, Olomouc, Czech Republic, September 27-29, 2018, Proceedings 17*. pp. 434–446. Springer (2018)
- [266] Thabet, D., Ghannouchi, S., Ben Ghezala, H.: Towards Business Process Model Extension with Cost Perspective based on Process Mining - Petri Net Model Case (05 2014)
- [267] Thakur, A., Konde, A.: Fundamentals of neural networks. *International Journal for Research in Applied Science and Engineering Technology* **9**, 407–26 (2021)
- [268] Thomas, U., Hirzinger, G., Rumpe, B., Schulze, C., Wortmann, A.: A new skill based robot programming language using uml/p statecharts. In: *2013 IEEE International Conference on Robotics and Automation*. pp. 461–466. IEEE (2013)
- [269] Tiftik, M.N., Erdogan, T.G., Tarhan, A.K.: A framework for multi-perspective process mining into a BPMN process model. *Mathematical Biosciences and Engineering* **19**(11), 11800–11820 (2022)
- [270] Tsakalidis, G., Vergidis, K., Delias, P., Vlachopoulou, M.: A Conceptual Business Process Entity with Lifecycle and Compliance Alignment. In: Freitas, P.S.A., Dargam, F., Moreno, J.M. (eds.) *Decision Support Systems IX: Main Developments and Future Trends*. pp. 70–82. Springer International Publishing, Cham (2019)
- [271] Valencia Parra, Á., Ramos Gutiérrez, B., Varela Vaca, Á.J., Gómez López, M.T., García Bernal, A.: Enabling process mining in aircraft manufactures: extracting event logs and discovering processes from complex data. In: *BPM2019IF: 17th International Conference on Business Process Management 2019 Industry Forum (2019)*, pp. 166-177. CEUR Workshop Proceedings (CEUR-WS. org) (2019)

- [272] Van Eck, M.L., Sidorova, N., Van der Aalst, W.M.: Enabling process mining on sensor data from smart products. In: 2016 IEEE Tenth International Conference on Research Challenges in Information Science (RCIS). pp. 1–12. IEEE (2016)
- [273] Van Renssen, A.: Gellish: an information representation language, knowledge base and ontology. In: ESSDERC 2003. Proceedings of the 33rd European Solid-State Device Research-ESSDERC'03 (IEEE Cat. No. 03EX704). pp. 215–228. IEEE (2003)
- [274] Vedaldi, A., Soatto, S.: Quick shift and kernel methods for mode seeking. In: Computer Vision–ECCV 2008: 10th European Conference on Computer Vision, Marseille, France, October 12–18, 2008, Proceedings, Part IV 10. pp. 705–718. Springer (2008)
- [275] Vergidis, K., Tiwari, A., Majeed, B.: Business process analysis and optimization: Beyond reengineering. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* **38**(1), 69–82 (2007)
- [276] Vom Brocke, J., Mathiassen, L., Rosemann, M.: Business process management (2014)
- [277] Wakchaware, S.: Large databases–association rule mining. *Int J Res Emerg Sci Technol* **1**(4), 19–26 (2014)
- [278] Wegerich, A., Löffler, D., Maier, A.: Handbuch zur IBIS Toolbox-Evaluation Intuitiver Benutzbarkeit. Bundesministerium für Bildung und Forschung (2018)
- [279] Weitlaner, D., Guettinger, A., Kohlbacher, M.: Intuitive comprehensibility of process models. In: S-BPM ONE-Running Processes: 5th International Conference, S-BPM ONE 2013, Deggendorf, Germany, March 11–12, 2013. Proceedings 5. pp. 52–71. Springer (2013)
- [280] Weske, M.: Business Process Management: Concepts, Languages, Architectures. Berlin (2007)
- [281] Wickramanayake, B., He, Z., Ouyang, C., Moreira, C., Xu, Y., Sindhgatta, R.: Building interpretable models for business process prediction using shared and specialised attention mechanisms. *Knowledge-Based Systems* **248**, 108773 (2022)
- [282] Wiedmann, P.C.K.: Agiles Geschäftsprozessmanagement auf Basis gebrauchssprachlicher Modellierung. Universitaet Bayreuth (Germany) (2017)
- [283] Winastwan, R.: Interpreting Image Classification Model with LIME. Should we trust our image classifier model?, <https://towardsdatascience.com/interpreting-image-classification-model-with-lime-1e7064a2f2e5>, zuletzt besucht: 26.10.2023
- [284] Wu, T., Chen, Y., Han, J.: Re-examination of interestingness measures in pattern mining: a unified framework. *Data Mining and Knowledge Discovery* **21**(3), 371–397 (2010)

- [285] Würf, J.: Evaluation ausgewählter Association Rule Mining Algorithmen. Bachelor's thesis, Universität Bayreuth (2023)
- [286] Xiong, H., Tan, P.N., Kumar, V.: Mining strong affinity association patterns in data sets with skewed support distribution. In: 3rd ICDM. pp. 387–394 (2003)
- [287] Xu, F., Uszkoreit, H., Du, Y., Fan, W., Zhao, D., Zhu, J.: Explainable AI: A brief survey on history, research areas, approaches and challenges. In: Natural Language Processing and Chinese Computing: 8th CCF International Conference, NLPCC 2019, Dunhuang, China, October 9–14, 2019, Proceedings, Part II 8. pp. 563–574. Springer (2019)
- [288] Yan, H., Paynabar, K., Shi, J.: Image-based process monitoring using low-rank tensor decomposition. *IEEE Transactions on Automation Science and Engineering* **12**(1), 216–227 (2014)
- [289] Yang, H., Park, M., Cho, M., Song, M., Kim, S.: A system architecture for manufacturing process analysis based on big data and process mining techniques. In: 2014 IEEE international conference on big data. pp. 1024–1029. IEEE (2014)
- [290] Yosinski, J., Clune, J., Nguyen, A., Fuchs, T., Lipson, H.: Understanding neural networks through deep visualization. arXiv preprint arXiv:1506.06579 (2015)
- [291] Zappa, D., Clemente, G.P., Borrelli, M., Savelli, N.: Text mining in insurance: From unstructured data to meaning. *Variance* **14**, 1–15 (2019)
- [292] Zeising, M.: Plattform zur integrierten IT-gestützten Ausführung von strikten und agilen Prozessen. Universitaet Bayreuth (Germany) (2015)
- [293] Zhan, L., Cheng, M., Zhu, J.: Progress on image analytics: Implications for tourism and hospitality research. *Tourism Management* **100**, 104798 (2024). doi: <https://doi.org/10.1016/j.tourman.2023.104798>
- [294] Zhao, Q., Bhowmick, S.S.: Association rule mining: A survey. Nanyang Technological University, Singapore **135** (2003)

VOLLSTÄNDIGE LISTE EIGENER PUBLIKATIONEN

Die nachfolgenden Publikationen sind thematisch in zwei Sektionen aufgeteilt. Zunächst folgen alle Publikationen, die im Kontext dieser Arbeit angefertigt wurden. Sie wurden von der Autorin in internationalen Journalen veröffentlicht, in Konferenzen aus dem Bereich Prozessmanagement vorgestellt und mit wissenschaftlichem Fachpublikum diskutiert. Die vorliegende Dissertation greift teilweise auf bereits veröffentlichte Inhalte zurück und präsentiert sie in einem erweiterten Detailgrad. Dabei werden Ansätze, Experimente und Ergebnisse in einem umfassenderen Rahmen betrachtet und ausführlich diskutiert. Anschließend folgt eine Auflistung anderer Publikationen des Autors, darunter auch aus anderen Fachbereichen.

THEMATISCH RELEVANTE PUBLIKATIONEN

Fichtner, M., Jablonski, S.: Applying Association Rules to Enhance Process Models through the Extraction of Relevant Process Details from Image Data. *Communications of the IBI-MA* (172169) (2024). doi: <https://doi.org/10.5171/2024.172169>

Fichtner, M., Sucker, S., Riedelbauch, D., Jablonski, S., Henrich, D.: Enriching Process Models with Relevant Process Details for Flexible Human-Robot Teaming. In: Gao, H., Wang, X., Voros, N. (eds.) *Collaborative Computing: Networking, Applications and Worksharing*. pp. 249–269. Springer Nature Switzerland, Cham (2024). doi: https://doi.org/10.1007/978-3-031-54531-3_14

Fichtner, M., Jablonski, S.: A Specification of How to Extract Relevant Process Details to Improve Process Models. In: Filipe, J., Śmiątek, M., Brodsky, A., Hammoudi, S. (eds.) *Enterprise Information Systems*. pp. 391–414. Springer Nature Switzerland, Cham (2023). doi: https://doi.org/10.1007/978-3-031-39386-0_19

Fichtner, M., Fichtner, U.A., Jablonski, S.: An Experimental Study of Intuitive Representations of Process Task Annotations. In: Cooperative Information Systems: 28th International Conference, CoopIS 2022, Bozen-Bolzano, Italy, October 4–7, 2022, Proceedings. pp. 311–321. Springer (2022). doi: https://doi.org/10.1007/978-3-031-17834-4_19

Fichtner, M., Schönig, S., Jablonski, S.: How LIME Explanation Models Can Be Used to Extend Business Process Models by Relevant Process Details. In: Proceedings of the 24th International Conference on Enterprise Information Systems - Volume 2: ICEIS. pp. 527–534. INSTICC, SciTePress (2022). doi: <https://doi.org/10.5220/0011067600003179>

Fichtner, M., Schönig, S., Jablonski, S.: Using Image Mining Techniques from a Business Process Perspective. In: Filipe, J., Śmiałek, M., Brodsky, A., Hammoudi, S. (eds.) Enterprise Information Systems. pp. 62–83. Springer International Publishing, Cham (2021). doi: https://doi.org/10.1007/978-3-030-75418-1_4

Fichtner, M., Schönig, S., Jablonski, S.: Process Management Enhancement by using Image Mining Techniques: A Position Paper. In: Proceedings of the 22nd International Conference on Enterprise Information Systems - Volume 1: ICEIS. pp. 249–255. INSTICC, SciTePress (2020). doi: <https://doi.org/10.5220/0009573502490255>

WEITERE PUBLIKATIONEN

Eisenhuth, P., Fichtner, M., Frede, B., Seesemann, R.: Developing Crosslingual Ontologies in WissKI: Transcontinental Research Collaboration in the Africa Multiple Cluster of Excellence. *Modern Languages Open* 2023 (1) (2023). doi: 10.3828/mlo.v0i0.445

Petter, S., Fichtner, M., Jablonski, S.: Considering User Preferences During Business Process Execution Using Content-Based Filtering. In: Filipe, J., Śmiałek, M., Brodsky, A., Hammoudi, S. (eds.) Enterprise Information Systems. pp. 415–429. Springer Nature Switzerland, Cham (2023)

Schützenmeier, N., Käppel, M., Fichtner, M., Jablonski, S.: Scenario-Based Model Checking of Declarative Process Models. In: Proceedings of the 25th International Conference on Enterprise Information Systems - Volume 2: ICEIS. pp. 406–417. INSTICC, SciTePress (2023)

Fichtner, U.A., Piotrowsky-Fichtner, M., Fichtner, M., Goßmann, A.K., Weis, F., Weiß, M., Steinmann, D.: Entwicklung konkreter Handlungsoptionen für die sichere Öffnung und den Betrieb von Freizeitdestinationen unter Pandemiebedingungen. *Zentralblatt für Arbeitsmedizin, Arbeitsschutz und Ergonomie* **72**(6), 267–277 (2022)

Huisl, J., Fichtner, M., Eisenhuth, P., Baumann, O., Schönfeld, M., Jablonski, S., Samimi, C.: Towards an Integrated and Contextualized Research Data Management at the Cluster of Excellence Africa Multiple. *University of Bayreuth African Studies Online* **9**, 155–172 (2022)

Petter, S., Fichtner, M., Schönig, S., Jablonski, S.: Content-based Filtering for Worklist Reordering to improve User Satisfaction: A Position Paper. In: *Proceedings of the 24th International Conference on Enterprise Information Systems - Volume 2: ICEIS*. pp. 589–596. INSTICC, SciTePress (2022)

Sturm, C., Fichtner, M., Schönig, S.: Full support for efficiently mining multi-perspective declarative constraints from process logs. *Information* **10**(1), 29 (2019)

Rohner, D., Fichtner, M., Henrich, D.: Vision-based Generation of Precedence Graphs. In: *Tagungsband des 4. Kongresses Montage Handhabung Industrieroboter*. pp. 13–22. Springer (2019)

Orendt, E.M., Fichtner, M., Henrich, D.: MINERIC toolkit: Measuring instruments to evaluate robustness and intuitiveness of robot programming concepts. In: *2017 26th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. pp. 1379–1386. IEEE (2017)

Orendt, E.M., Fichtner, M., Henrich, D.: Robot programming by non-experts: Intuitiveness and robustness of one-shot robot programming. In: *2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. pp. 192–199. IEEE (2016)

ANHANG

A	Fragebögen der Nutzerstudie	
	A1: Fragebogen 1 (Demografie und Vorwissen)	221
	A2: Fragebogen 2a (Effektivität (GUV) nach [278])	223
	A3: Fragebogen 2b (Mentale Effizienz (SEA) nach [73, 278])	225
	A4: Fragebogen 2c (Zufriedenheit (QUESI) nach [120, 278])	227
	A5: Fragebogen 3 (Interpretation der Aufgabenbeschreibung)	229
B	Prozessmodelle der Nutzerstudie	
	B1: Prozessmodelle der Studie: Platzierungsaufgabe	231
	B2: Prozessmodelle der Studie: Stapelaufgabe	233
	B3: Prozessmodelle der Studie: Sortieraufgabe	235
C	Grafiken zu den Ergebnissen der Nutzerstudie	
	C1: Deskriptive Statistik der drei Aspekte (Repräsentation und Vorwissen) . . .	237
	C2: Deskriptive Statistik der drei Aspekte (Repräsentation und Aufgabenstellung)	239
	C3: Tabellen zur Studie (Hypothesen 1b und 1c):	241
	C4: Grafiken zur Studie (Hypothese 2, Effektivität)	243
	C5: Grafiken zur Studie (Hypothese 2, Mentale Anstrengung)	245
	C6: Grafiken zur Studie (Hypothese 2, Zufriedenheit)	247
	C7: Grafiken zur Studie (Hypothese 2, Zufriedenheit - QUESI-Subskalen)	249

A1: FRAGEBOGEN 1 (DEMOGRAFIE UND VORWISSEN)

Vorwissen und Anleitungspräferenz

- *Zunächst: kurze Abklärung, was der Studienteilnehmer unter einem Prozessmodell versteht*
- Ich habe schon einmal mit Prozessmodellen gearbeitet: ja nein
- Ich habe aktiv mit Prozessmodellen gearbeitet: Jahr(e) Monat(e)
..... Woche(n) Stunden
- Ich arbeite mit Prozessmodellen im folgenden Kontext:
- Modellierung
 - Ausführung
 - Beides
- Wenn ich etwas Neues tun soll oder mir selbst beibringen muss, dann bevorzuge ich eine Anleitung, die **vorwiegend**...
- textgestützt ist
(vgl. Kochrezept, Spielanleitung, Packungsbeilage)
 - bildgestützt ist (Grafik/Foto/Video)
(vgl. Montageanleitung (Möbel), Youtube-Videos (Haar schneiden))
 - diagramm- oder listengestützt ist
(vgl. Schritt-für-Schritt-Anleitungen (Corona-Selbsttest), Verhaltensanweisungen (Autowaschen))

Daten zur Person

- Alter Jahre
- Geschlecht
- Männlich
 - Weiblich
 - Divers
- Höchster Schul- oder Hochschulabschluss
- Ohne Abschluss
 - Hauptschulabschluss
 - Realschulabschluss
 - Abitur
 - Hochschul-/Fachhochschulabschluss
- Fachrichtung:
- Position
- Berufserfahrung Jahre

A2: FRAGEBOGEN 2A (EFFEKTIVITÄT (GUV) NACH [278])

Beobachtung der Modellausführung	
Genauigkeit:	
<input type="checkbox"/> 3	Der Nutzer/Die Nutzerin hat die Aufgabe ohne Probleme gelöst.
<input type="checkbox"/> 2	Der Nutzer/Die Nutzerin hat die Aufgabe mit Trial&Error bearbeitet.
<input type="checkbox"/> 1	Der Nutzer/Die Nutzerin hat die Aufgabe mit einem einzigen Hinweis des Moderators/der Moderatorin bearbeitet.
<input type="checkbox"/> 0	Der Nutzer/Die Nutzerin hat die Aufgabe mit permanenter Unterstützung des Moderators/der Moderatorin bearbeitet.
Vollständigkeit:	
<input type="checkbox"/> 2	Die Aufgabe wurde vollständig erfüllt.
<input type="checkbox"/> 1	Die Aufgabe wurde teilweise erfüllt.
<input type="checkbox"/> 0	Die Aufgabe wurde nicht erfüllt.

Weitere Beobachtungen:

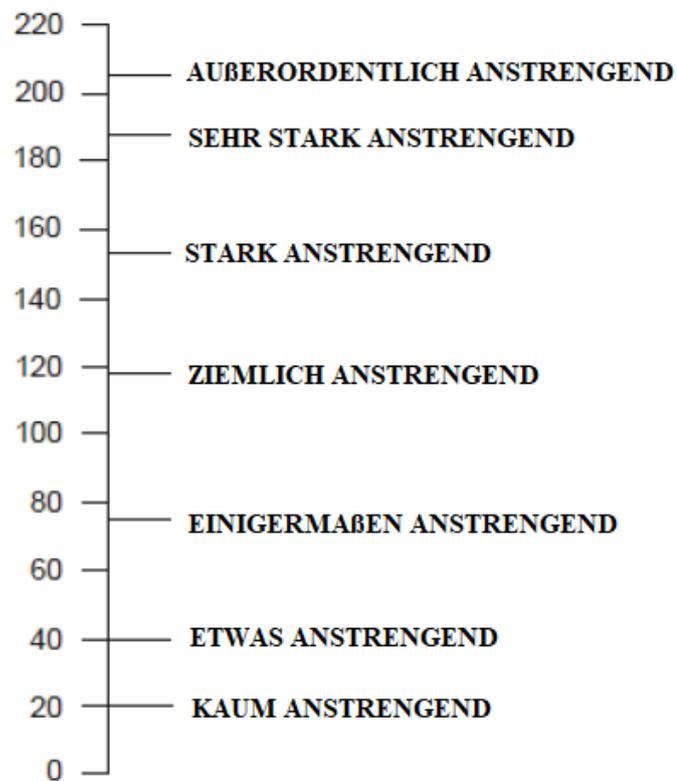
--

Dauer:

A3: FRAGEBOGEN 2B (MENTALE EFFIZIENZ (SEA) NACH [73, 278])

Beanspruchungshöhe

Bitte bewerten Sie Ihre geistige Anstrengung in Bezug auf die gerade absolvierte Folge von Aufgaben durch ein einzelnes Kreuz auf der folgenden Skala.



A4: FRAGEBOGEN 2C (ZUFRIEDENHEIT (QUESI) NACH [120, 278])

Wie bewerten Sie die Aufgabenanweisungen?

		trifft gar nicht zu	trifft wenig zu	trifft teils- teils zu	trifft ziemlich zu	trifft völlig zu
1	Es gelang mir, die Aufgabenanweisungen ohne Nachdenken umzusetzen.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
2	Ich habe erreicht, was ich durch die Aufgabenanweisungen erreichen wollte.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3	Mir war sofort klar, was die Aufgabenanweisungen bedeuten.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4	Die Darstellung der Aufgabenanweisungen erschien mir vertraut.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
5	Bei der Umsetzung der Aufgabenanweisungen sind keine Probleme aufgetreten.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
6	Die Umsetzung der Aufgabenanweisungen war unkompliziert.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
7	Es gelang mir, meine Ziele so zu erreichen, wie ich es mir vorgestellt habe.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
8	Es fiel mir von Anfang an leicht, die Aufgabenanweisungen umzusetzen.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
9	Mir war immer klar, was ich tun musste, um die Aufgabenanweisungen umzusetzen.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10	Die Umsetzung der Aufgabenanweisungen verlief reibungslos.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
11	Ich musste mich kaum auf die Umsetzung der Aufgabenanweisungen konzentrieren.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
12	Die Aufgabenanweisungen haben mich dabei unterstützt, meine Ziele vollständig zu erreichen.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
13	Die Aufgabenanweisungen waren mir auf Anhieb klar.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
14	Ich tat immer automatisch das Richtige, um mein Ziel zu erreichen.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

A5: FRAGEBOGEN 3 (INTERPRETATION DER AUFGABENBESCHREIBUNG)

Prozessmodell 1:

Platzieren
 Text

Stapeln
 Bild

Sortieren
 Diagramm

Frage	Eigene Entscheidung	Anweisung im Modell vorgegeben
Warum ist Bauteil __ <i>dort</i> positioniert?		
Warum befindet sich Bauteil __ <i>dort</i> und Bauteil __ <i>daneben/darüber/gegenüber/...?</i>		
Warum ist Bauteil __ <i>so</i> orientiert?		
Warum wurden die Bauteile in <i>der</i> Reihenfolge platziert?		

Prozessmodell 2:

Platzieren
 Text

Stapeln
 Bild

Sortieren
 Diagramm

Frage	Eigene Entscheidung	Anweisung im Modell vorgegeben
Warum ist Bauteil __ <i>dort</i> positioniert?		
Warum befindet sich Bauteil __ <i>dort</i> und Bauteil __ <i>daneben/darüber/gegenüber/...?</i>		
Warum ist Bauteil __ <i>so</i> orientiert?		
Warum wurden die Bauteile in <i>der</i> Reihenfolge platziert?		

Prozessmodell 3:

Platzieren
 Text

Stapeln
 Bild

Sortieren
 Diagramm

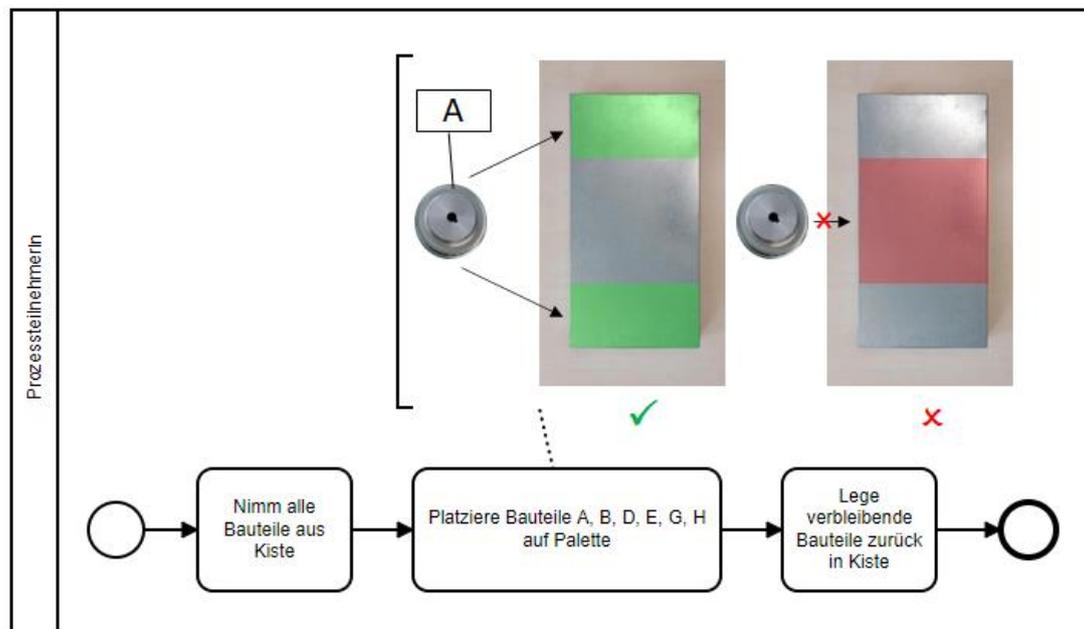
Frage	Eigene Entscheidung	Anweisung im Modell vorgegeben
Warum ist Bauteil __ <i>dort</i> positioniert?		
Warum befindet sich Bauteil __ <i>dort</i> und Bauteil __ <i>daneben/darüber/gegenüber/...?</i>		
Warum ist Bauteil __ <i>so</i> orientiert?		
Warum wurden die Bauteile in <i>der</i> Reihenfolge platziert?		

B1: PROZESSMODELLE DER STUDIE: PLATZIERUNGSAUFGABE

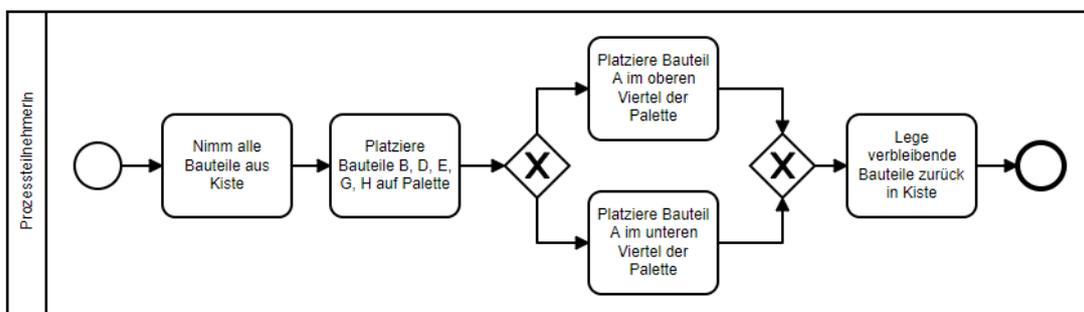
A1:



A2:

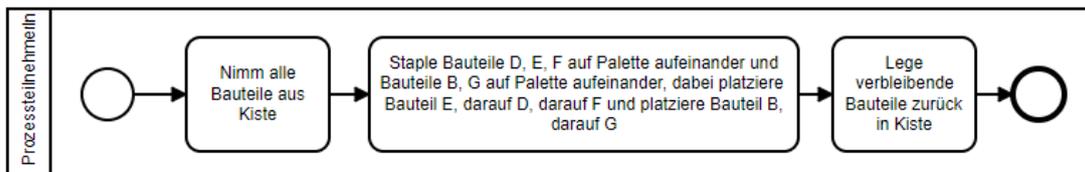


A3:

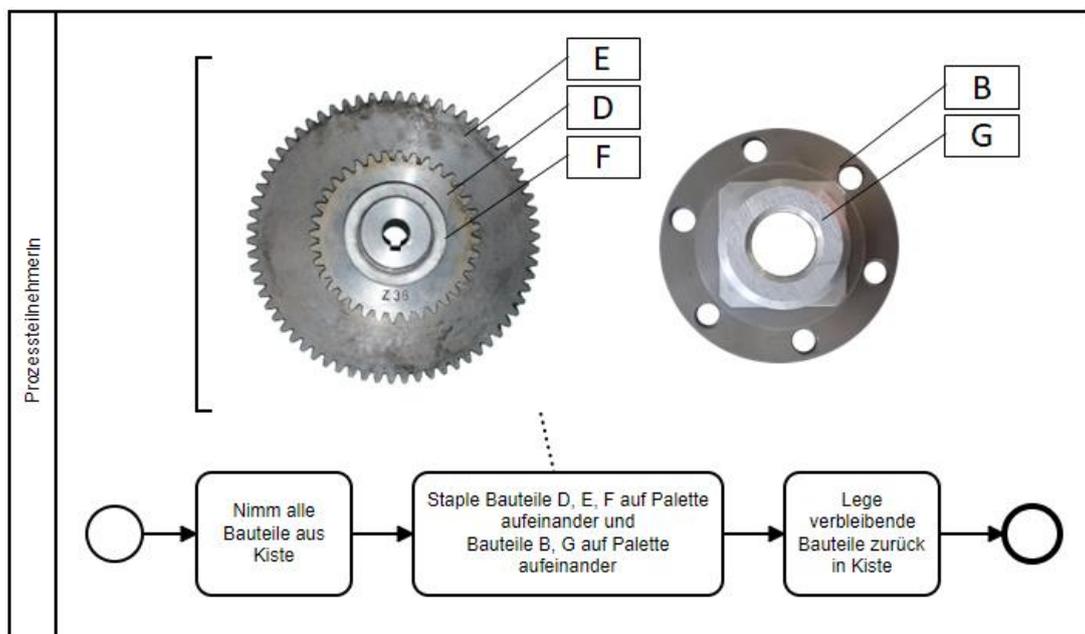


B2: PROZESSMODELLE DER STUDIE: STAPELAUFGABE

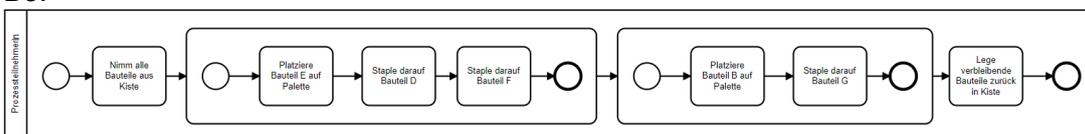
B1:



B2:

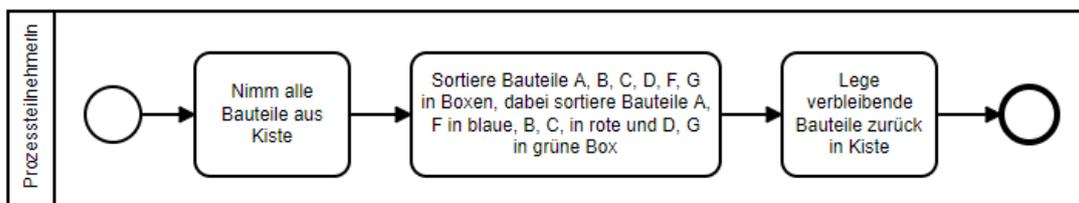


B3:

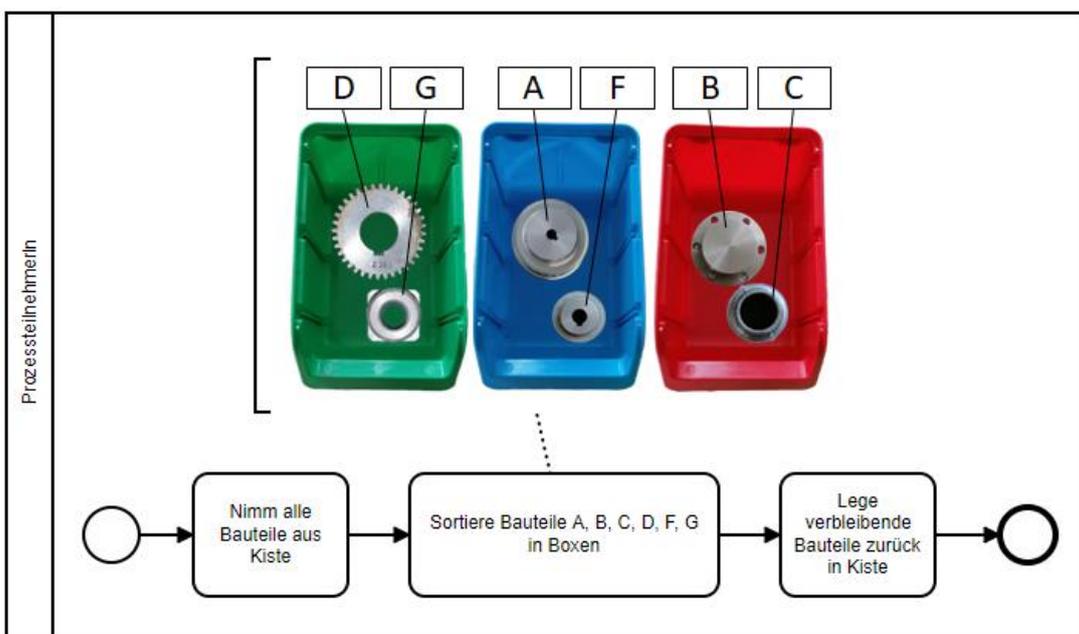


B3: PROZESSMODELLE DER STUDIE: SORTIERAUFGABE

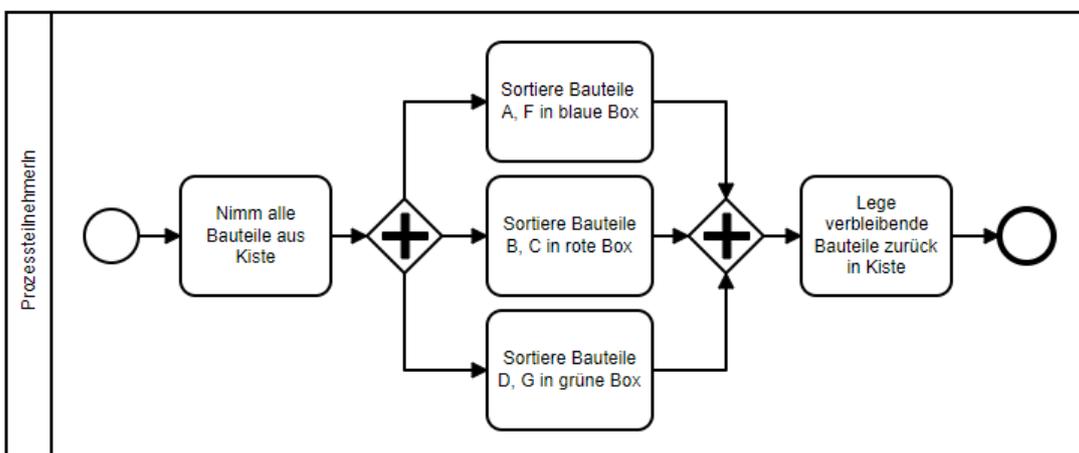
C1:



C2:

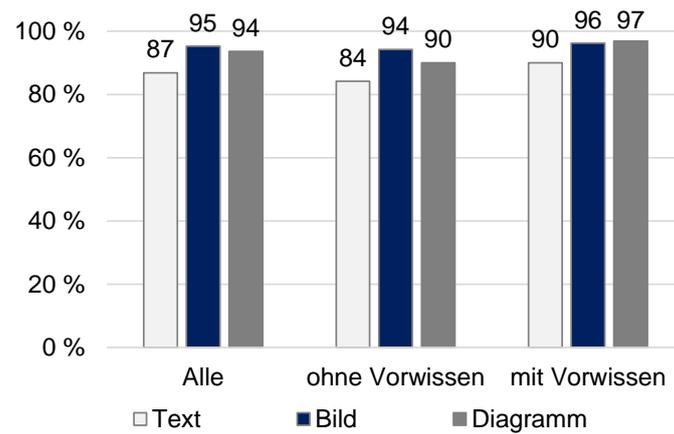


C3:

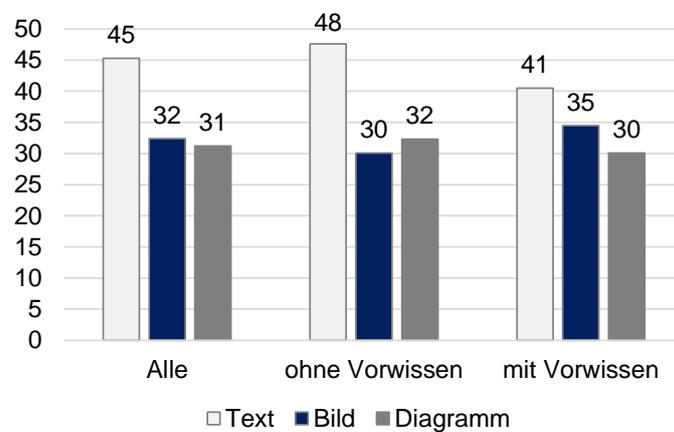


C1: DESKRIPTIVE STATISTIK DER DREI ASPEKTE (REPRÄSENTATION UND VORWISSEN)

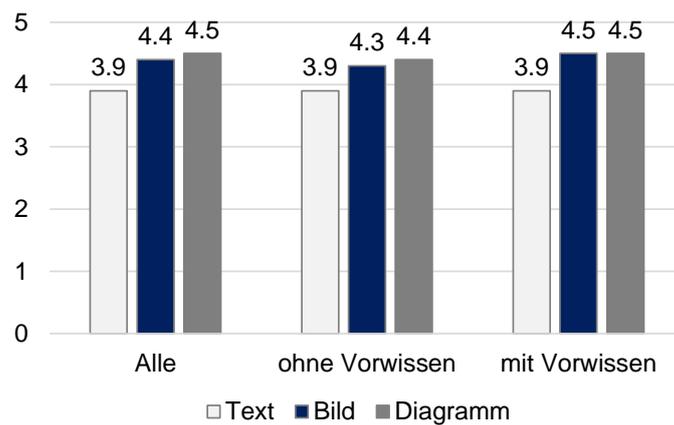
Effektivität:



Mentale Anstrengung:

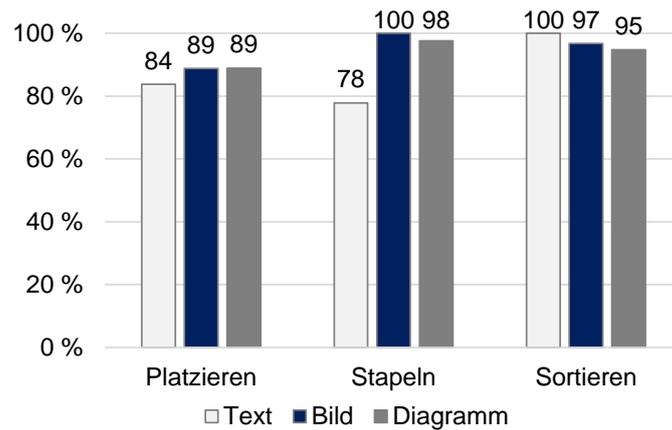


Zufriedenheit:

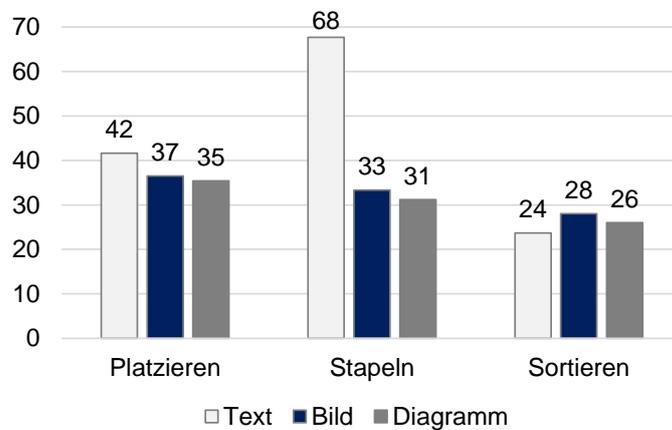


C2: DESKRIPTIVE STATISTIK DER DREI ASPEKTE (REPRÄSENTATION UND AUFGABENSTELLUNG)

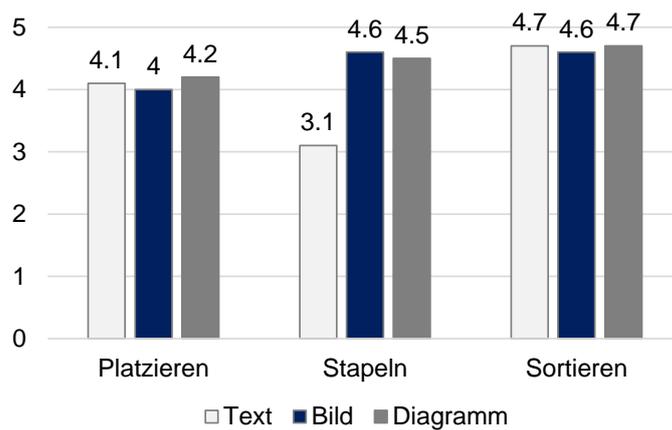
Effektivität:



Mentale Anstrengung:



Zufriedenheit:



C3: TABELLEN ZUR STUDIE (HYPOTHESEN 1B UND 1C):

Tabelle: Varianzanalyse mit Satterthwaites Methode: LMMs mit Expertise (Hypothese 1b)

	LMM1			LMM2			LMM3		
	Effektivität			Mentale Anstrengung			Zufriedenheit		
	QM	F	p	QM	F	p	QM	F	p
Repräsentationsformat (RF)	852.89	3.46	0.04	2655.70	5.71	0.00	3.84	12.59	0.00
Aufgabenstellung	1313.32	5.33	0.01	4657.40	10.02	0.00	5.89	19.29	0.00
Experte vs. Laie (Prozessmodelle)	557.03	2.26	0.14	6.50	0.01	0.91	0.38	1.27	0.27
RF: Aufgabenstellung	837.63	3.40	0.01	1092.40	2.35	0.06	2.48	8.12	0.00
RF: Experte	79.41	0.32	0.72	229.90	0.49	0.61	0.06	0.19	0.82
Aufgabenstellung: Experte	263.17	1.07	0.34	217.00	0.47	0.63	0.00	0.01	0.98
RF: Aufgabenstellung: Experte	237.80	0.97	0.42	411.90	0.89	0.47	0.08	0.26	0.90
Marginales R ²	0.21			0.17			0.37		

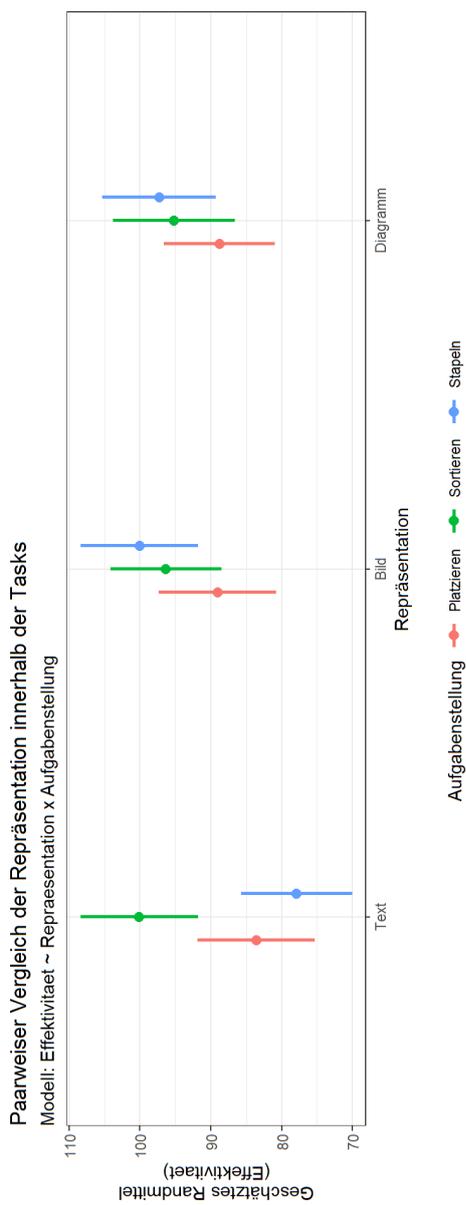
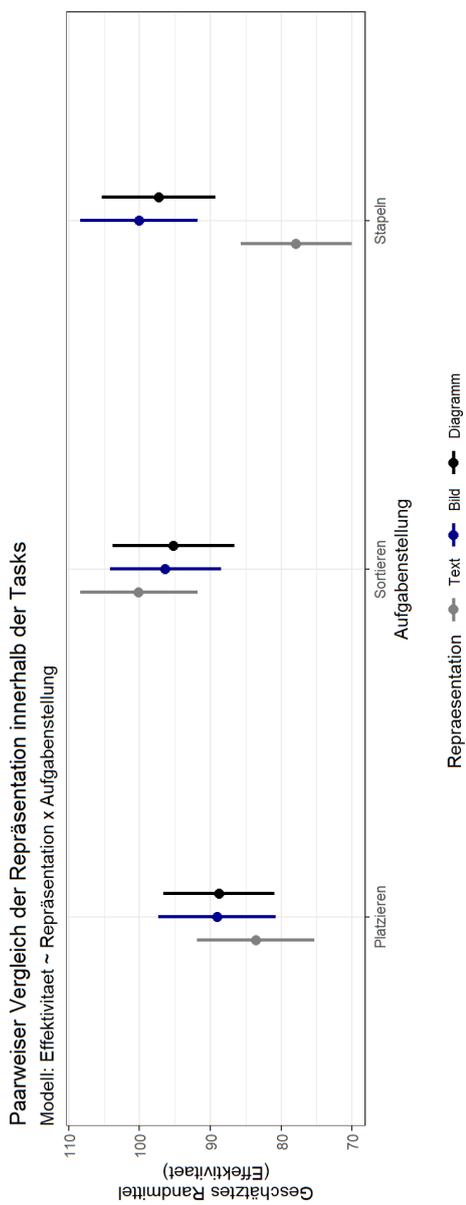
Notiz: Interaktionsterme als Kombination von zwei Variablen sind markiert mit ":", Quadriertes Mittel wird abgekürzt als QM

Tabelle: Varianzanalyse mit Satterthwaites Methode: LMMs mit Bildungsabschluss (Hypothese 1c)

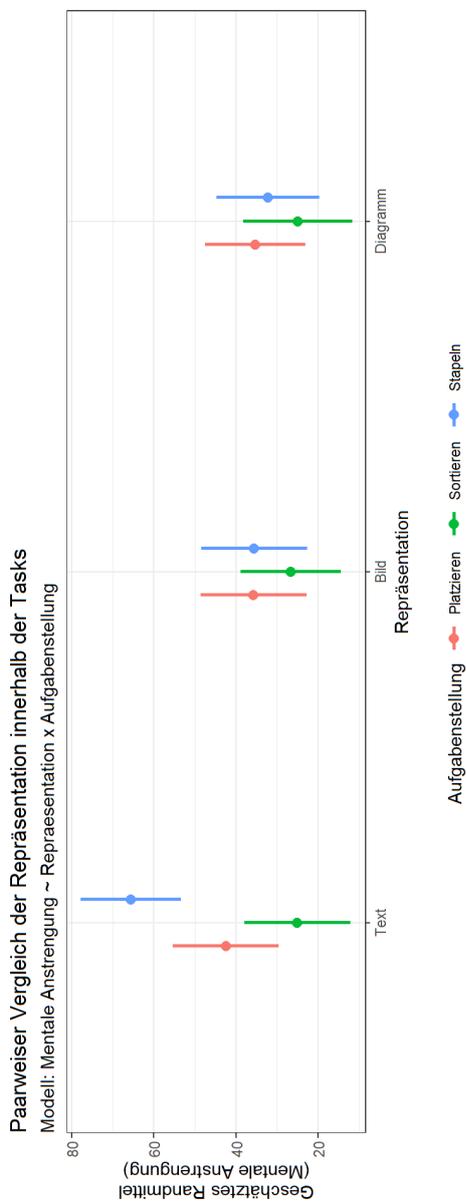
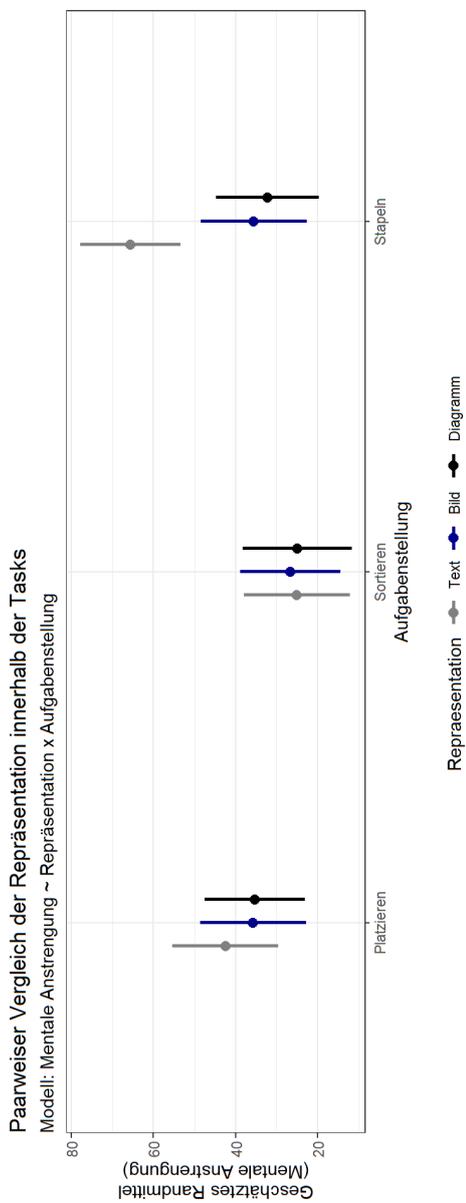
	LMM1			LMM2			LMM3		
	Effektivität			Mentale Anstrengung			Zufriedenheit		
	QM	F	p	QM	F	p	QM	F	p
Repräsentationsformat (RF)	1222.22	5.71	0.00	1483.09	3.01	0.06	2.80	9.02	0.00
Aufgabenstellung	1845.76	8.62	0.00	1787.56	3.62	0.03	3.02	9.72	0.00
Höchster Bildungsabschluss (HB)	1379.67	6.44	0.00	373.76	0.76	0.56	0.39	1.24	0.31
RF: Aufgabenstellung	1082.26	5.05	0.00	1019.83	2.07	0.09	1.78	5.71	0.00
RF: HB	394.00	1.84	0.08	505.74	1.03	0.42	0.30	0.98	0.46
Aufgabenstellung: HB	599.45	2.80	0.02	266.34	0.54	0.78	0.20	0.66	0.69
RF: Aufgabenstellung: HB	368.12	1.72	0.07	318.10	0.65	0.80	0.18	0.57	0.86
Marginales R ²	0.42			0.24			0.43		

Notiz: Interaktionsterme als Kombination von zwei Variablen sind markiert mit ":", Quadriertes Mittel wird abgekürzt als QM

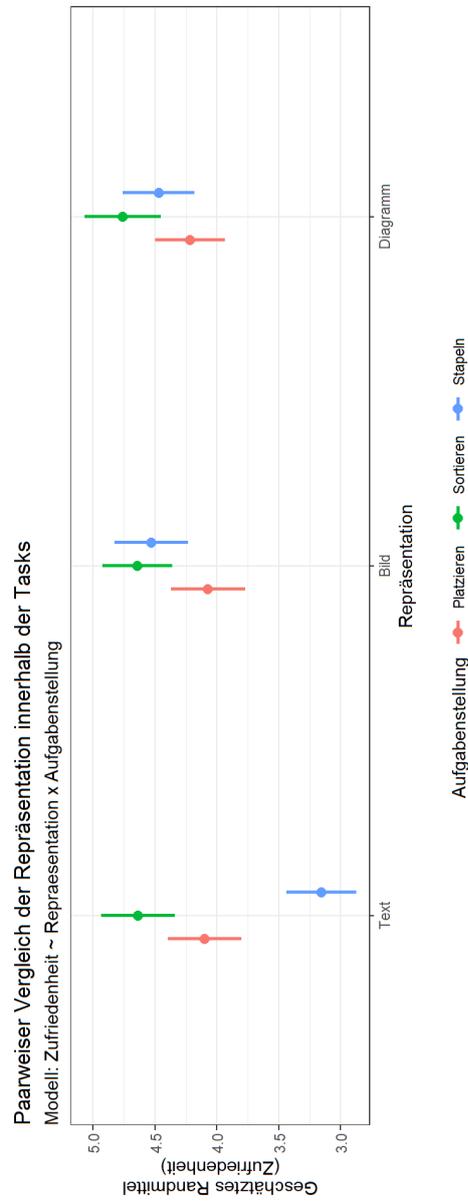
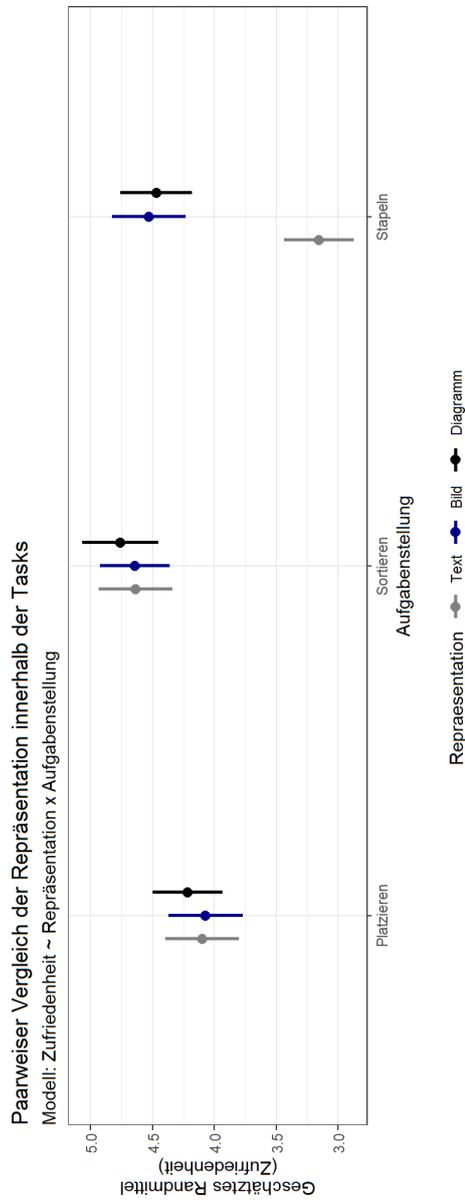
C4: GRAFIKEN ZUR STUDIE (HYPOTHESE 2, EFFEKTIVITÄT)



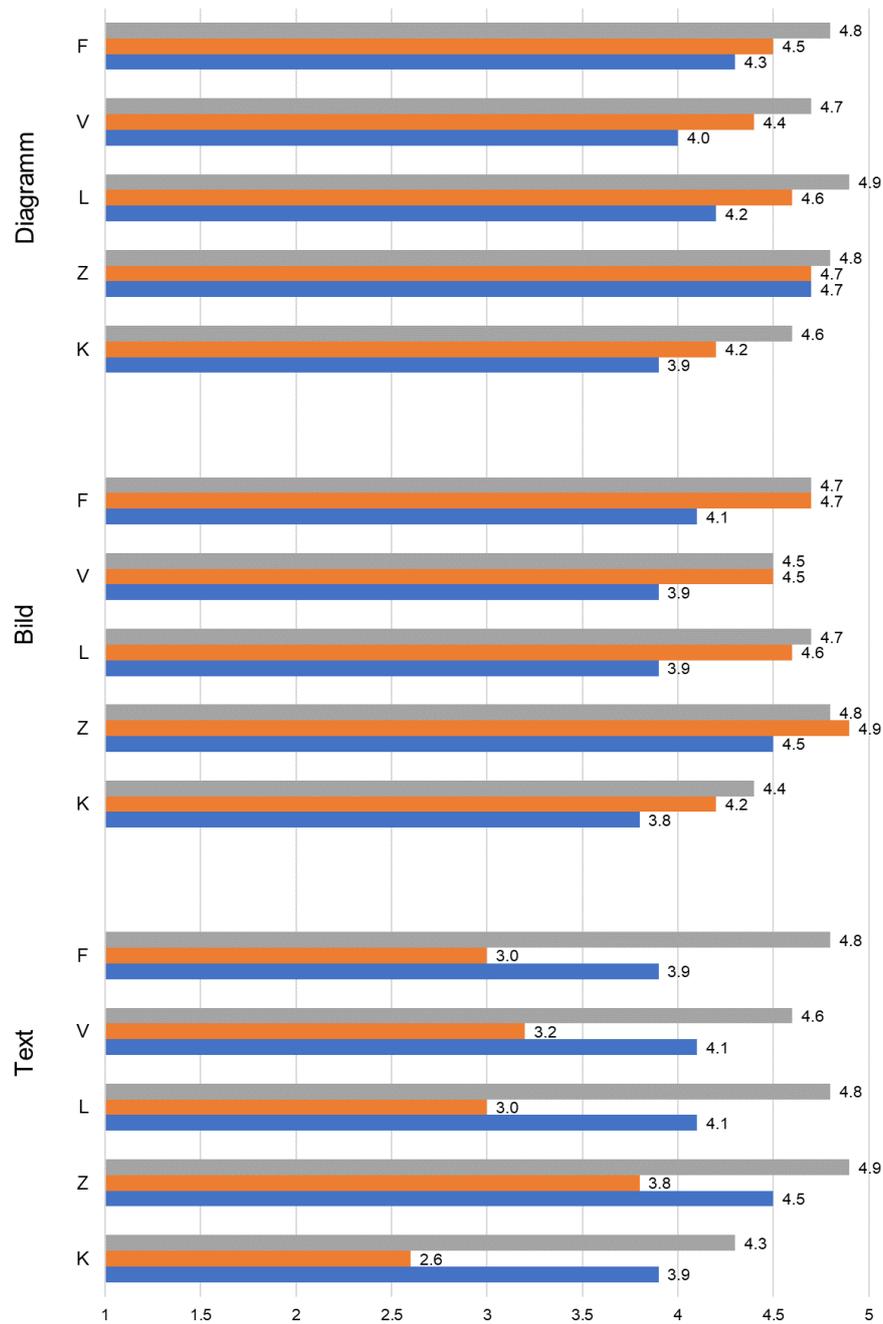
C5: GRAFIKEN ZUR STUDIE (HYPOTHESE 2, MENTALE ANSTRENGUNG)



C6: GRAFIKEN ZUR STUDIE (HYPOTHESE 2, ZUFRIEDENHEIT)



C7: GRAFIKEN ZUR STUDIE (HYPOTHESE 2, ZUFRIEDENHEIT - QUESI-SUBSKALEN)



K - Wahrgenommene kognitive Beanspruchung
 Z - Wahrgenommene Zielerreichung
 L - Wahrgenommener Lernaufwand
 V - Vertrautheit
 F - Wahrgenommene Fehlerrate

■ Sortieren ■ Stapeln ■ Platzieren