

**Lernendes und erklärbares System zur
Entscheidungsunterstützung in der Produktionssteuerung**

Philipp Sebastian Theumer

Vollständiger Abdruck der von der TUM School of Engineering and Design der Technischen Universität München zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.)
genehmigten Dissertation.

Vorsitz: Prof. Dr.-Ing. Michael F. Zäh
Prüfer der Dissertation: 1. Prof. Dr.-Ing. Gunther Reinhart
2. Prof. Dr. Marco Caccamo

Die Dissertation wurde am 27.05.2024 bei der Technischen Universität München eingereicht und durch die TUM School of Engineering and Design am 08.11.2024 angenommen.

Geleitwort der Herausgeber

Die Produktionstechnik ist in Zeiten globaler Herausforderungen, wie der Klimakrise, dem Mobilitätswandel und der Überalterung der Gesellschaft in westlichen Ländern, für eine nachhaltige Weiterentwicklung unserer Industriegesellschaft von zentraler Bedeutung. Der Einfluss eines Industriebetriebs auf die Umwelt und die Gesellschaft hängt dabei entscheidend von den eingesetzten Produktionsmitteln, den angewandten Produktionsverfahren und der eingeführten Produktionsorganisation ab. Erst das optimale Zusammenspiel von Mensch, Organisation und Technik erlaubt es, alle Potenziale für den Unternehmenserfolg auszuschöpfen. Dabei muss größtes Augenmerk darauf gelegt werden, möglichst ressourcenschonend, effizient und resilient zu werden, um flexibel im volatilen Produktionsumfeld zu agieren.

Um in dem Spannungsfeld Nachhaltigkeit, Komplexität, Kosten, Zeit und Qualität bestehen zu können, müssen Produktionsstrukturen ständig neu überdacht und weiterentwickelt werden. Dabei ist es notwendig, die Komplexität von Produkten, Produktionsabläufen und -systemen einerseits zu verringern und andererseits besser zu beherrschen.

Ziel der Forschungsarbeiten des *iwb* ist die ständige Verbesserung von Produktentwicklungs- und Planungssystemen, von Herstellverfahren sowie von Produktionsanlagen. Betriebsorganisation, Produktions- und Arbeitsstrukturen sowie Systeme zur Auftragsabwicklung werden unter besonderer Berücksichtigung der Anforderungen des Personals sowie von Nachhaltigkeitsaspekten entwickelt. Die dabei eingesetzten rechnergestützten und Künstliche-Intelligenz-basierten Methoden und die notwendige Steigerung des Automatisierungsgrades dürfen jedoch nicht zu einer Verfestigung arbeitsteiliger Strukturen führen. Fragen der optimalen Einbindung ökologischer und sozialer Aspekte in alle Planungs- und Entwicklungsprozesse spielen deshalb eine sehr wichtige Rolle.

Die im Rahmen dieser Buchreihe erscheinenden Bände stammen thematisch aus den Forschungsbereichen des *iwb*. Diese reichen von der Entwicklung von Produktionssystemen über deren Planung bis hin zu den eingesetzten Technologien in den Bereichen Fertigung und Montage. Die Steuerung und der Betrieb von Produktionssystemen, die Qualitätssicherung, die Verfügbarkeit und die Autonomie

sind Querschnittsthemen hierfür. In den *iwb*-Forschungsberichten werden neue Ergebnisse und Erkenntnisse aus der praxisnahen Forschung des Institutes veröffentlicht. Diese Buchreihe soll dazu beitragen, den Wissenstransfer zwischen dem Hochschulbereich und den Anwendenden zu verbessern.

Rüdiger Daub

Gunther Reinhart

Michael Zäh

Vorwort

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Fraunhofer-Institut für Gießerei-, Composite- und Verarbeitungstechnik IGCV in Augsburg sowie am Institut für Werkzeugmaschinen und Betriebswissenschaften (*iwb*) der Technischen Universität München.

Mein besonderer Dank gilt meinem Doktorvater Herrn Prof. Dr.-Ing. Gunther Reinhart für die wohlwollende und konstruktive Unterstützung dieser Arbeit sowie für die kontinuierliche Förderung meiner Tätigkeit am Institut. Ebenso möchte ich mich bei Herrn Prof. Dr. Marco Caccamo für die Übernahme des Korreferats und bei Herrn Prof. Dr.-Ing. Michael F. Zäh für die Übernahme des Vorsitzes der Prüfungskommission bedanken.

Für die wertvollen Anmerkungen und die gründliche Durchsicht meiner Arbeit möchte ich mich besonders bei Lukas Bank, Dr.-Ing. Jan Klöber-Koch, Dr. med. dent. Verena Theumer und Dr.-Ing. Alexander Zipfel bedanken. Darüber hinaus gilt mein Dank allen Kolleginnen und Kollegen. Die gemeinsame Zeit am Institut hat mich nachhaltig geprägt und war ein ganz besonderer Lebensabschnitt, den ich nicht missen möchte. Weiterhin möchte ich mich bei allen Studentinnen und Studenten, die mich bei der Entstehung dieser Arbeit unterstützt haben, bedanken.

Von ganzem Herzen möchte ich mich bei meiner Familie für den grenzenlosen Rückhalt und die bedingungslose Unterstützung bedanken. Ihr habt mir diesen Ausbildungsweg ermöglicht und habt mich in meinem Promotionsvorhaben stets bestärkt.

Mein größter Dank gilt meiner Frau Verena – für ihre unermüdliche Unterstützung und Motivation in allen Phasen meiner Promotion sowie für ihr Verständnis für die Arbeit an der Dissertation. Ohne deinen Rückhalt, deine bestärkenden Worte und deinen Frohsinn wäre die Vollendung dieser Arbeit nicht möglich gewesen.

Crailsheim, im Februar 2025

Philipp Sebastian Theumer

Inhaltsverzeichnis

Inhaltsverzeichnis.....	i
Abkürzungsverzeichnis.....	vii
Verzeichnis der Formelzeichen.....	ix
1 Einleitung	1
1.1 Ausgangssituation und Motivation	1
1.2 Zielsetzung der Arbeit.....	5
1.3 Forschungsmethodisches Vorgehen und Aufbau der Arbeit.....	7
2 Stand des Wissens	11
2.1 Allgemeines.....	11
2.2 Begriffsbestimmung.....	11
2.3 Produktionsplanung und -steuerung	12
2.3.1 Zielsystem der Produktionsplanung und -steuerung.....	12
2.3.2 Aufgaben der Produktionsplanung und -steuerung	14
2.3.3 Modell der Fertigungssteuerung	15
2.3.4 Daten- und Informationsmanagement.....	19
2.3.5 Adaptive Ansätze zur Produktionssteuerung.....	24
2.4 Agenten und Agentensysteme.....	27
2.4.1 Allgemeines	27
2.4.2 Agenten und Agentensysteme	27
2.4.3 Umgebung eines Agentensystems.....	29
2.5 Reinforcement Learning	31

2.5.1	Allgemeines	31
2.5.2	Deep Reinforcement Learning	33
2.5.3	Agentensysteme zur Produktionssteuerung	35
2.6	Ansätze zur Erklärbarkeit	39
2.6.1	Allgemeines	39
2.6.2	Erklärbarkeit im Kontext von Maschinellem Lernen	39
2.6.3	Ansätze zur Erklärbarkeit von systemischen Entscheidungen im Produktionsumfeld	42
2.7	Entscheidungstheorie und Entscheidungsunterstützungssysteme	44
2.7.1	Allgemeines	44
2.7.2	Entscheidungsmodell	45
2.7.3	Ansätze zur Entscheidungsunterstützung	46
2.8	Ableitung des Handlungsbedarfs	50
2.9	Fazit	52
3	Lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung	53
3.1	Allgemeines	53
3.2	Anforderungen an ein lernendes und erklärbares System zur Entscheidungsunterstützung	53
3.3	Systemelemente	56
4	Benutzerrollenspezifisches Informationsmodell	59
4.1	Allgemeines	59
4.2	Nutzungskontext	61
4.2.1	Benutzerrollen	61
4.2.2	Maßnahmenreferenzkatalog	65

4.3	Kategorien der Entscheidungsunterstützung	67
4.3.1	Duale Architektur der Entscheidungspsychologie.....	68
4.3.2	Definition unterschiedlicher Kategorien der Entscheidungsunterstützung.....	72
4.3.3	Kategorien der Entscheidungsunterstützung im Kontext der dualen Architektur der Entscheidungspsychologie	75
4.4	Benutzerrollenspezifisches Referenzmodell.....	76
4.5	Vorgehen zur unternehmensspezifischen Anpassung des Informationsmodells	77
4.6	Fazit	79
5	Lernende benutzerrollenspezifische Produktionssteuerung.....	81
5.1	Allgemeines.....	81
5.2	Modellierung des Produktionssystems	82
5.3	Agentensystem	85
5.3.1	Benutzerzentrierte Entwurfsmuster für Agenten	86
5.3.2	Zustandsraum.....	89
5.3.3	Aktionsraum	91
5.4	Anpassung und Implementierung eines geeigneten Reinforcement- Learning-Verfahrens	93
5.4.1	Verwendeter Deep-Reinforcement-Learning-Algorithmus.....	94
5.4.2	Trainingsaufbau	96
5.4.3	Belohnungsfunktion	97
5.4.4	Training des Agentensystems.....	98
5.5	Vorgehen zur unternehmensspezifischen Erstellung der lernenden benutzerrollenspezifischen Produktionssteuerung	103
5.6	Fazit	106

6	Erklärbarkeit von systemischen Entscheidungen	107
6.1	Allgemeines.....	107
6.2	Integration der Erklärbarkeit von systemischen Entscheidungen in den Entscheidungsfindungsprozess	107
6.3	Klassifizierung und Bewertung von Erklärbarkeitsansätzen	109
6.3.1	Merkmalsrelevanz	112
6.3.2	Kontrafaktuale	116
6.3.3	Verknüpfung der Verfahren	119
6.4	Vorgehen zur Integration in das lernende System zur Entscheidungsunterstützung	119
6.5	Fazit	123
7	Technische Umsetzung	125
7.1	Allgemeines.....	125
7.2	Beschreibung des betrachteten Produktionssystems	125
7.2.1	Produktionssystem.....	127
7.2.2	Aktueller Ablauf der Produktionssteuerung	129
7.2.3	Herausforderung.....	129
7.3	Anwendung des lernenden und erklärbaren Systems zur Produktionssteuerung.....	131
7.3.1	Allgemeines	131
7.3.2	Erstellen des unternehmens- und benutzerrollenspezifischen Informationsmodells.....	132
7.3.3	Technische Umsetzung	134
7.4	Simulationsbasierte Umsetzung.....	144
7.4.1	Simulationsszenarien.....	144
7.4.2	Verifizierung des Simulationsmodells	146

7.4.3 Ergebnisse der Simulationsstudie	148
7.5 Fazit	151
8 Kritische Würdigung	153
8.1 Allgemeines	153
8.2 Anforderungsbezogene Bewertung	153
8.3 Wirtschaftliche Bewertung der Anwendung	155
8.3.1 Aufwand	156
8.3.2 Nutzen	158
8.4 Voraussetzungen und Limitationen	159
8.5 Fazit	159
9 Zusammenfassung und Ausblick	161
9.1 Zusammenfassung	161
9.2 Ausblick	163
10 Literaturverzeichnis	165
11 Betreute Studienarbeiten	183
12 Abbildungsverzeichnis	185
13 Tabellenverzeichnis	191
14 Anhang	193
14.1 Auswirkungen von Maßnahmen auf Kennzahlen	193
14.2 Deep SHAP	194
14.3 Anwendungsfall	195

14.3.1 Clusteranalyse mit Hilfe des k-Means-Algorithmus	195
14.3.2 Erklärbarkeitsansätze.....	196

Abkürzungsverzeichnis

DiCE	Diverse Counterfactual Explanations
DNN	Deep Neural Network (dt. tiefe neuronale Netze)
DRL	Deep Reinforcement Learning
DRM	Design Research Methodology
ERP	Enterprise Resource Planning
FIFO	First In – First Out
FPE	frühester Plan-Endtermin
FPS	frühester Plan-Starttermin
i. A.	in Anlehnung
<i>iwb</i>	Institut für Werkzeugmaschinen & Betriebswissenschaften der TU München
KI	Künstliche Intelligenz
LIME	Local Interpretable Model-Agnostic Explanations
KNN	Künstliches Neuronales Netz
MEP	Markov-Entscheidungsprozess
MES	Manufacturing Execution System
ML	Maschinelles Lernen
OPP	Operative Produktionsperformance
PPO	Proximal Policy Optimization
PPS	Produktionsplanung und -steuerung
REFA	Verband für Arbeitsgestaltung, Betriebsorganisation und Unternehmensentwicklung e. V.
RFID	Radio-Frequency Identification

RL	Reinforcement Learning
SHAP	Shapley Additive Explanations
SSTN	Shortest Setup Time Next
UML	Unified Modeling Language
VDE	Verband der Elektrotechnik Elektronik Informati- onstechnik e. V.
VDI	Verein Deutscher Ingenieure e. V.
XAI	explainable artificial intelligence (dt. erklärbare künstliche Intelligenz)

Verzeichnis der Formelzeichen

Symbol	Bedeutung
a_{erw}	<i>erwartetes Ergebnis</i>
a_t	<i>Aktion zum Zeitpunkt t</i>
\hat{a}	<i>Entscheidungsvorschlag</i>
A	<i>Menge möglicher Aktionen</i>
A_{alt}	<i>Menge möglicher Alternativen</i>
$A_{\hat{a}t}$	<i>ausgewählte Alternativen</i>
$AnzAVG$	<i>Anzahl Arbeitsvorgänge</i>
$AnzÜA$	<i>Anzahl übergangener Aufträge</i>
B_{gesamt}	<i>Gesamtbelohnung</i>
B_{global}	<i>globale Belohnung</i>
B_{lokal}	<i>lokale Belohnung</i>
c	<i>Kontrafaktual</i>
$C_{\Delta x \Delta o}$	<i>Veränderung der Modellausgabe in Abhängigkeit von der Veränderung der Modelleingabe</i>
$diversity(c)$	<i>Diversitätsterm für die Berechnung der Kontrafaktuale</i>
e_{KF}	<i>textuelle Ausgabe der Kontrafaktuale</i>
e_{SHAP}	<i>berechnete Merkmalsrelevanz</i>
E_{as}	<i>Ergebnismatrix zur Beurteilung von Handlungsalternativen</i>
E_{π}	<i>Erwartungswerte der Strategie</i>
$f(c)$	<i>Ausgabe für das Kontrafaktual c</i>
$\hat{f}(h_x(z))$	<i>Vorhersagemodell</i>
$g(z)$	<i>Surrogatmodell</i>
inv_s	<i>Maske ungültiger Aktionen</i>
$L(\hat{f}, g, \pi_x)$	<i>Verlustfunktion</i>
M	<i>max. Größe einer Koalition</i>

ob_m	<i>Beobachtung, die den Systemzustand beinhaltet</i>
OPP	<i>operative Produktionsperformance</i>
p	<i>Übergangswahrscheinlichkeit der Umgebung</i>
$q_\pi(s, a)$	<i>Aktions-Wertfunktion der Strategie π im Zustand s und der Aktion a</i>
r_t	<i>Belohnung zum Zeitpunkt t</i>
R_t	<i>Erwartungswert der Belohnung zum Zeitpunkt t</i>
RD	<i>Reihenfolgedisziplin</i>
s_t	<i>Zustand zum Zeitpunkt t</i>
S	<i>Zustandsraum von Agenten</i>
S_{Umwelt}	<i>Umweltzustände</i>
T	<i>Episodendauer</i>
$v_\pi(s)$	<i>Zustands-Wertfunktion der Strategie π im Zustand s</i>
w_g	<i>Gewichtungsfaktor der globalen Belohnung</i>
w_l	<i>Gewichtungsfaktor der lokalen Belohnung</i>
$w(S_{Umwelt})$	<i>Wahrscheinlichkeitsurteil eines Entscheiders über das Eintreten der Umweltzustände</i>
$yloss(f(\mathbf{c}), y)$	<i>Verlustfunktion der Berechnung von Kontrafaktualen</i>
z	<i>Vektor zur Beschreibung der Koalition</i>

Symbol	Bedeutung
γ	<i>Diskontierungsfaktor</i>
λ	<i>Hyperparameter zur Gewichtung einzelner Terme</i>
$\pi(a_t s_t)$	<i>Strategie in Abhängigkeit des Zustands-Aktions-Paars</i>
$\pi_{x'}(z')$	<i>SHAP Kernel</i>
Φ_o	<i>durchschnittlicher Erwartungswert</i>
Φ_i	<i>Beitrag eines Merkmals i zu einem Ergebnis</i>
$\phi(A_{alt})$	<i>Präferenzfunktion zur Bewertung von Handlungsalternativen</i>

1 Einleitung

1.1 Ausgangssituation und Motivation

Die Globalisierung und der damit einhergehende Konkurrenzdruck sowie das volatile Marktumfeld (REINHART & ZÜHLKE 2017) stellen das produzierende Gewerbe vor die Herausforderung, die Logistikleistung¹ bei gleichzeitiger Reduzierung der Logistikkosten zu erhöhen (SCHMIDT & NYHUIS 2021a). Zudem ist neben den gestiegenen Anforderungen an die Logistikleistung und die Logistikkosten ein deutliches Variantenwachstum bei nahezu gleichbleibenden Stückzahlen erkennbar (WILDEMANN 2009, ENGELHARDT 2015). Eine Studie von BANK ET AL. (2021) erfasst die Veränderung des Produktportfolios der befragten Unternehmen. In den letzten 10 Jahren hat sich bei zwei Drittel der befragten Unternehmen die angebotene Variantenanzahl mindestens verzehnfacht (BANK ET AL. 2021). Dieser Trend induziert eine steigende Komplexität in der Planung und Steuerung der Produktionsabläufe (KLETTI 2015a, NYHUIS ET AL. 2016) und stellt die Produktionsplanung und -steuerung (PPS) vor die Herausforderung, trotz steigender Komplexität einen effektiven und effizienten Produktionsablauf zu gewährleisten (WIENDAHL & WIENDAHL 2019). Der durch die steigende Variantenanzahl größer werdende Lösungsraum möglicher Handlungsalternativen bedingt eine zunehmende Entscheidungskomplexität im Produktionsumfeld, welcher sich Mitarbeiter² unterschiedlichster Ebenen ausgesetzt sehen (ELMARAGHY ET AL. 2012, NELLES ET AL. 2016). Beispielhaft für die durch das Variantenwachstum induzierte Komplexität in der PPS steht die Reihenfolgebildung. Durch die höhere Variantenanzahl bei gleichzeitig niedrigeren Losgrößen steigt die Anzahl möglicher Kombinationen bei der Reihenfolgebildung. Damit die bestmögliche Reihenfolge gewählt werden kann, müssen u. a. unterschiedliche Rüstzeiten, Bearbeitungszeiten und notwendige Prozessschritte berücksichtigt werden (LÖDDING 2016, WIENDAHL & WIENDAHL 2019).

¹ Eine hohe Logistikleistung zeichnet sich durch kurze Lieferzeiten sowie eine hohe Liefertreue, charakterisiert durch eine hohe Termintreue der Auftragsabwicklung, aus. Die Logistikkosten setzen sich aus Kapitalbindungskosten (beeinflusst durch Bestände) sowie Prozesskosten für die Auftragsabwicklung (beeinflusst durch die Auslastung) zusammen (WIENDAHL & WIENDAHL 2019).

² In dieser Arbeit wird nur die männliche Sprachform verwendet. Dies dient lediglich der Beibehaltung eines hohen Maßes an Lesbarkeit. Sämtliche Bezeichnungen gelten jedoch ausdrücklich gleichermaßen für alle Geschlechter.

Durch eine Beherrschung der beschriebenen Komplexität kann eine hohe Logistikleistung erzielt werden, welche ein Differenzierungsmerkmal darstellt und somit einen Wettbewerbsvorteil bietet (NYHUIS & WIENDAHL 2012, BRAMBRING 2017, WIENDAHL & WIENDAHL 2019). Eine geringe logistische Leistungsfähigkeit kann sich in einem Verlust der Kundenbindung äußern, da bspw. keine unternehmensinterne Priorisierung von Aufträgen ausgewählter Kunden realisierbar ist.

Die Leistungsfähigkeit der PPS – und dadurch die Wirtschaftlichkeit eines Unternehmens – wird durch auftretende Planänderungen während des Produktionsablaufs und die Reaktion auf ebendiese beeinflusst (WIENDAHL & WIENDAHL 2019, SCHMIDT & NYHUIS 2021a). Hauptgründe für Planabweichungen sind einerseits ein mangelndes Verständnis der Mitarbeiter für die Logistikleistung und -kosten und die daraus resultierenden, ungeeigneten Steuerungsentscheidungen sowie andererseits kurzfristige Maschinenausfälle (NYHUIS ET AL. 2016). Damit eine hohe logistische Leistungsfähigkeit erreicht werden kann, besteht der Bedarf einer angemessenen Reaktionsfähigkeit auf unvorhergesehene Ereignisse bei gleichzeitig hoher Güte der Entscheidungen (KLETTI 2015a). Durch eine zielführende Produktionssteuerung kann unmittelbar auf Abweichungen vom Produktionsplan unter Berücksichtigung unternehmensintern priorisierter produktionslogistischer Zielgrößen (z. B. hohe Termintreue) reagiert werden. Durch das zeitnahe Festlegen und Auslösen von geeigneten Maßnahmen (z. B. Umplanung eines Auftrags auf eine andere Anlage) können die negativen Auswirkungen auf das Produktionssystem (z. B. Stillstände aufgrund eines Materialflussabbrisses) vermieden werden (KLETTI 2015a). Somit kann der Verlust der logistischen Leistungsfähigkeit verhindert werden (VASSILYEV ET AL. 2013, KLETTI 2015a, OLUYISOLA ET AL. 2020).

In der Regel erfolgt die Durchführung der PPS unter Verwendung IT-gestützter Hilfsmittel (MEIBNER ET AL. 2015). Allerdings geben zwei Drittel der befragten Unternehmen an, dass ihre für die Aufgaben der PPS eingesetzten IT-Systeme den zukünftigen Aufgaben nicht gewachsen sind (NYHUIS ET AL. 2016). Ein Indiz für eine bereits vorhandene mangelnde Beherrschung der Komplexität im Kontext der Produktionssteuerung durch bestehende Systeme zeigt sich in der Häufigkeit, mit welcher manuelle Umplanungen durchgeführt werden (siehe Abbildung 1-1). In der von LÖDDING (2019) durchgeführten Studie gaben nur 19 % der Befragten an, dass die von PPS-Systemen (z. B. Manufacturing Execution System [MES], Enterprise Resource Planning [ERP] System) generierte Planung angenommen und nicht übersteuert wird. Eine Übersteuerung eines bestehenden Plans kann bspw.

Die Planung/Entscheidungsunterstützung von PPS-Systemen wird von den Mitarbeitern angenommen. Es findet keine manuelle Übersteuerung durch Mitarbeiter statt.

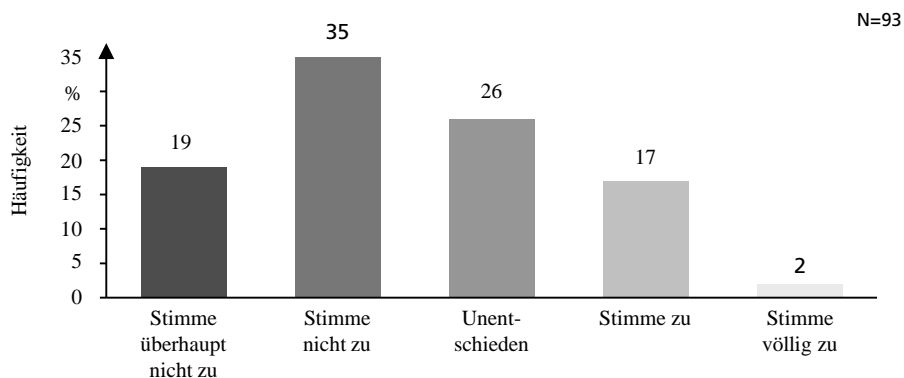


Abbildung 1-1: Häufigkeit der Übersteuerung der Planung von PPS-Systemen durch Mitarbeiter (i. A. an LÖDDING 2019)

die Auswahl eines Auftrags entgegen der Planung des PPS-Systems sein. Gründe hierfür liegen in einer geringen Eignung der IT-Systeme oder in der fehlenden Akzeptanz der systemisch vorgeschlagenen Lösungen bei den Mitarbeitern (BANK ET AL. 2021). Verschärfend entspricht die in den PPS-Systemen abgebildete Informationsmenge nicht den Bedürfnissen der Benutzer (LÖDDING 2019).

Im Spannungsfeld zwischen der Anforderung einer hohen Reaktionsfähigkeit und der Notwendigkeit einer hohen Lösungsgüte in einem komplexen Umfeld bietet der Einsatz von Verfahren des Maschinellen Lernens (ML) ein erhebliches Potenzial (BYRNE ET AL. 2018, CADAVID ET AL. 2020). Mit Hilfe von ML-Verfahren kann einerseits die in der Produktionssteuerung bedeutsame Reaktionszeit im Vergleich zu anderen Optimierungsverfahren (z. B. analytischen Optimierungsverfahren) verringert und andererseits die Entscheidungsqualität gegenüber bspw. Heuristiken (z. B. First In – First Out [FIFO]) verbessert werden, indem eine Vielzahl unterschiedlicher Daten in relativ kurzer Zeit verarbeitet werden kann (DÖBEL ET AL. 2018, WANG ET AL. 2018). In Abbildung 1-2 wird beispielhaft das Potenzial eines solchen ML-basierten Systems gezeigt. Hierbei dient die Wahrscheinlichkeit, eine verspätete Bestellung rechtzeitig zu liefern, als Indikator für eine hohe Leistungsfähigkeit der PPS. Der Einsatz von ML-Verfahren bietet das Potenzial einer verkürzten Reaktionszeit sowie einer gesteigerten Entscheidungsqualität, wodurch die Wahrscheinlichkeit, dass eine verspätete Bestellung rechtzeitig geliefert wird, erhöht wird.

Voraussetzung für den Einsatz von performanten ML-Verfahren ist die Verfügbarkeit von Daten (DÖBEL ET AL. 2018). Diese ist durch den schnellen Fortschritt im

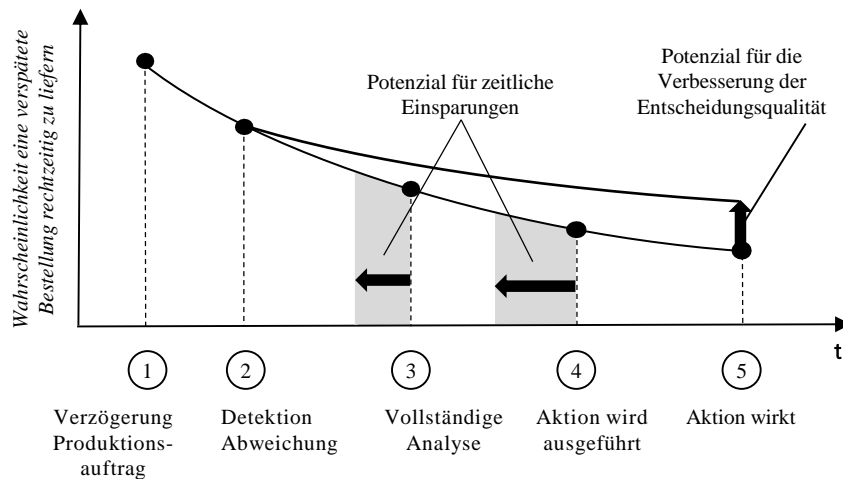


Abbildung 1-2: Potenzial eines Systems zur Entscheidungsunterstützung in der PPS (i. A. an SCHUH ET AL. 2017, STEINLEIN ET AL. 2020)

Bereich der Sensoren, Netzwerke und Speicherung von Daten, kombiniert mit deren geringen Kosten, gegeben. (BUYYA ET AL. 2016) Ein spezielles ML-Verfahren, welches ein bedeutendes Potenzial für den Einsatz in der Produktionssteuerung birgt, ist das Reinforcement Learning³ (RL) (CADAVID ET AL. 2020). RL-Verfahren eignen sich besonders zur Lösung von komplexen und dynamischen Entscheidungsproblemen (DU & DING 2021), wie sie in der Produktionssteuerung auftreten. Hierbei muss der Lösungsweg nicht explizit vorgegeben werden, sondern ein geeignetes Verhalten wird basierend auf einer zu definierenden Zielfunktion und Interaktionen mit dem (Produktions-)System erlernt (SUTTON & BARTO 2018).

Eine noch zu lösende Herausforderung im Kontext der PPS ist die Steigerung des Vertrauens der Benutzer in die Lösungen der eingesetzten PPS-Systeme (LÖDDING 2019). Diese bieten zwar unterschiedliche Funktionen an, um die Aufgaben der PPS zu lösen, allerdings zeigt eine Studie von LÖDDING (2019), dass nur knapp 35 % der Befragten ihr Vertrauen in die Ergebnisse der eingesetzten PPS-Systeme als hoch einstufen. Im Kontext von ML-Verfahren wird diese bereits bestehende Problematik weiter verschärft. Beim Einsatz von ML-Verfahren kommen häufig sogenannte Blackbox-Modelle (z. B. künstliche neuronale Netze [KNN]) zum Einsatz, bei welchen die Lösungsfindung nicht erklärbar⁴ ist (DÖBEL ET AL. 2018).

³ Dt. *bestärkendes Lernen*

⁴ Der Begriff *explainable artificial intelligence (XAI)* im Englischen und *erklärbare künstliche Intelligenz (KI)* im Deutschen ist als Bezeichnung für das Wissensgebiet, welches sich mit der Nachvollziehbarkeit von durch Computersysteme getroffenen Entscheidungen auseinandersetzt, etabliert. *Erklärbarkeit* bzw. das Adjektiv *erklärbar* bedeutet laut DUDENREDAKTION (2024) „das Erklärbarsein“ bzw. „sich erklären lassend“. Im Kontext dieser Arbeit wird diese Bedeutung erweitert und die Erklärbarkeit wird als das aktive Bereitstellen einer nachvollziehbaren Begründung aufgefasst. Diese ermöglicht es dem Benutzer die Entscheidung eines ML-Modells nachzuvollziehen. (BARREDO ARRIETA ET AL. 2020)

Neben der Performanz der Algorithmen wird deshalb ihrer Erklärbarkeit bzw. ihren Resultaten besondere Bedeutung zugemessen. Die Erklärbarkeit der Algorithmen kann das Vertrauen der Mitarbeiter in die Resultate der Algorithmen steigern (BURKART ET AL. 2021) und somit perspektivisch die Anzahl der Umplanungen aufgrund von fehlender Akzeptanz der Lösungen reduzieren. Zusammenfassend ist festzustellen, dass zur Verbesserung der Leistungsfähigkeit der PPS sowohl technische als auch soziologische Aspekte betrachtet werden müssen, um die steigende Komplexität beherrschen und gleichzeitig die Akzeptanz von systemischen Entscheidungen durch die Mitarbeiter steigern zu können.

1.2 Zielsetzung der Arbeit

Das übergeordnete Ziel dieser Arbeit ist es, Mitarbeiter in Entscheidungssituationen in der Produktionssteuerung unter Berücksichtigung der logistischen Zielgrößen zu unterstützen. Ein besonderer Aspekt, welchen es hierbei zu beachten gilt, ist das Vertrauen in systemische Entscheidungen. Zur Zielerreichung wird im Rahmen dieser Arbeit ein *lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung* entwickelt. Damit soll eine automatisierte Auswahl von Handlungsalternativen ermöglicht werden. Die Einbindung von Mitarbeitern in die Systementwicklung ermöglicht deren zielgerichtete Unterstützung im produktiven Betrieb. Dies ist eine wichtige Voraussetzung, um die richtigen Informationen zur richtigen Zeit am richtigen Ort zur Verfügung stellen zu können. Somit kann die Akzeptanz von systemischen Entscheidungen gesteigert (KLETTI & DEISENROTH 2021) und perspektivisch die Anzahl der Übersteuerungen durch Mitarbeiter reduziert werden. Dies wiederum hat einen positiven Einfluss auf die logistische Leistungsfähigkeit und beeinflusst letzten Endes die Wirtschaftlichkeit des Unternehmens positiv. In Abbildung 1-3 sind die Zielstellung sowie die abgeleiteten Subziele dargestellt.

Das *benutzerrollenspezifische Informationsmodell* bildet die Grundlage für das lernende und erklärbare System zur Entscheidungsunterstützung. Hierbei gilt es, ein methodisches Vorgehen zu entwickeln, um die an Entscheidungssituationen im Kontext der Produktionssteuerung beteiligten Mitarbeiter und den für diese Entscheidungen notwendigen Informationsbedarf zu identifizieren. Der Handlungsspielraum dieser Mitarbeiter sowie deren Unterstützungsbedarf müssen anschließend bestimmt und strukturiert erfasst werden. Insbesondere für den Unterstützungsbedarf gilt es, den menschlichen Entscheidungsprozess zu berücksichtigen.

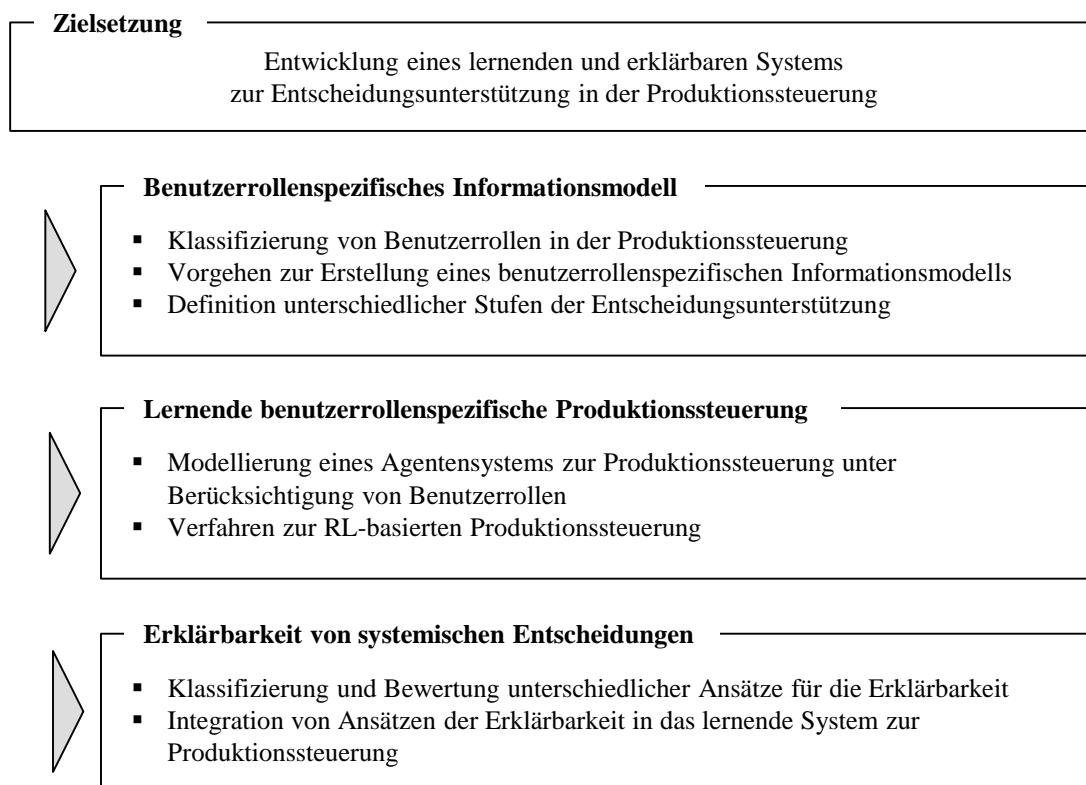


Abbildung 1-3: Zielsetzung der Arbeit mit daraus abgeleiteten Subzielen

Die *lernende benutzerrollenspezifische Produktionssteuerung* ermöglicht es, in Entscheidungssituationen Handlungsempfehlungen für die identifizierten Benutzer, unter Berücksichtigung des aktuellen Zustands des Produktionssystems, zu generieren. Dafür gilt es, das Produktionssystem zu modellieren und den Informationsbedarf des Mitarbeiters zu berücksichtigen. Für die Auswahl der am besten geeigneten Handlungsalternative soll RL eingesetzt werden, damit sowohl die Reaktionsfähigkeit auf unvorhergesehene Ereignisse als auch eine hohe Lösungsgüte realisiert werden können.

Zur *Erklärbarkeit von systemischen Entscheidungen* werden bestehende Ansätze aus dem Bereich der erklärbaren Künstlichen Intelligenz analysiert, klassifiziert, bewertet und adaptiert. Dies ermöglicht es, systemische Entscheidungen zu erklären. Ausgewählte Erklärbarkeitsansätze werden anschließend in das lernende System zur Produktionssteuerung integriert.

1.3 Forschungsmethodisches Vorgehen und Aufbau der Arbeit

Die von ULRICH & HILL (1976) entwickelte Wissenschaftssystematik kann zur wissenschaftstheoretischen Einordnung dieser Arbeit herangezogen werden. Hierbei wird zwischen den *Formal-* und den *Realwissenschaften* unterschieden. Formalwissenschaften sind durch das Ziel der Konstruktion von Zeichensystemen und Regeln zur Verwendung derselben gekennzeichnet. Philosophie, Logik und Mathematik können den Formalwissenschaften zugeordnet werden. Innerhalb der Realwissenschaften kann zwischen der Erklärung empirisch wahrnehmbarer Wirklichkeitsausschnitte – den reinen Grundlagenwissenschaften – und der Analyse menschlicher Handlungsalternativen – den angewandten Handlungswissenschaften – differenziert werden. Der Fokus der angewandten Handlungswissenschaften liegt auf der Gestaltung von technischen und sozialen Systemen zur Analyse und Gestaltung von Handlungsalternativen. (ULRICH & HILL 1976) Ausgehend von einer praxisbezogenen Fragestellung hat die vorliegende Arbeit das Ziel, Mitarbeiter in Entscheidungssituationen im Kontext der Produktionssteuerung zu unterstützen. Somit ist die Arbeit den angewandten Handlungswissenschaften zuzuordnen.

Zur Strukturierung der praxisbezogenen Fragestellung wird ausgehend von der Zielsetzung der Arbeit (siehe Abschnitt 1.2) ein heuristischer Bezugsrahmen erstellt. Dieser unterstützt die Erarbeitung einer differenzierten Perspektive auf die Fragestellung und die Entwicklung einer über die initialen Annahmen hinausgehende Lösung. (KUBICEK 1977) Im Zentrum des heuristischen Bezugsrahmens steht das System zur Entscheidungsunterstützung in der Produktionssteuerung. Jede Kategorie steht mit dem zentralen Kernthema sowie den anderen Kategorien in einer Wechselwirkung (siehe Abbildung 1-4). Bei den Kategorien handelt es sich um die *Produktionstechnik*, die *Arbeitswissenschaft* sowie die *angewandte Informatik*. Diese werden im Folgenden detailliert.

Der Bezug zur industriellen Praxis sowie der Handlungsbedarf nach einem System zur Entscheidungsunterstützung in der Produktionssteuerung ist der Produktionstechnik zuordenbar. Bei der Entwicklung des Systems gilt es sowohl funktionale als auch ökonomische Anforderungen zu berücksichtigen. In direkter Wechselwirkung mit der Produktionstechnik steht die Arbeitswissenschaft und die angewandte Informatik. Die Arbeitswissenschaft – als interdisziplinäres Fachgebiet – beinhaltet die Auseinandersetzung mit der Gestaltung der Arbeitsumgebung. Dabei wird einerseits auf eine hohe Effektivität und Effizienz bei der Ausübung der

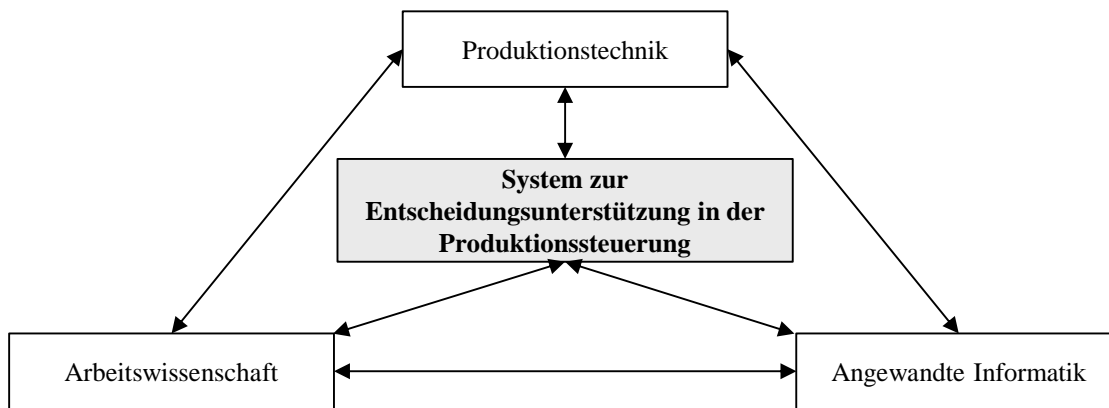


Abbildung 1-4: Heuristischer Bezugsrahmen dieser Arbeit

Arbeitstätigkeit geachtet und andererseits die Bedürfnisse des Benutzers berücksichtigt. Die angewandte Informatik – zu der auch das Teilgebiet ML zählt – bietet unterschiedliche Methoden zur Bearbeitung der Zielsetzung sowie zur Realisierung von Applikationen. Unter Berücksichtigung dieses heuristischen Bezugsrahmens gilt es, ein forschungsmethodisches Vorgehen zu wählen, welches die zielgerichtete und strukturierte Gewinnung neuer Erkenntnisse unterstützt.

Das im Rahmen dieser Arbeit eingesetzte forschungsmethodische Vorgehen basiert auf der von BLESSING & CHAKRABARTI (2009) entwickelten *Design Research Methodology (DRM)*. Die DRM erhöht durch die Bereitstellung von Methoden und Richtlinien die Wahrscheinlichkeit, dass valide und nützliche Ergebnisse erzielt werden. Das gewählte Vorgehen wirkt unterstützend auf den gestalterischen Kern der Arbeit – der Entwicklung eines Systems zur Produktionssteuerung – und begünstigt somit das effektive und effiziente Beantworten der wissenschaftlichen Fragestellungen. Innerhalb der DRM folgt die vorliegende Arbeit dem Typ 3, dem Erarbeiten einer Lösung. Ausgehend von einem identifizierten Handlungsbedarf wird dabei eine konkrete Lösung entwickelt. Die DRM stellt ein generisches Regelwerk zur Verfügung, welches die systematische Beantwortung von Forschungsfragen unterstützt. (BLESSING & CHAKRABARTI 2009)

Abbildung 1-5 zeigt die einzelnen Schritte der DRM. Diese sind die *Klärung des Forschungsziels*, die *Deskriptive Studie I*, die *Präskriptive Studie* und die *Deskriptive Studie II*. Ziel der ersten Stufe der DRM, der Klärung des Forschungsziels, ist eine evidenzbasierte Formulierung des Forschungsziels inklusive daraus ableitbarer Subziele. Hierfür ist es notwendig, ein Grundverständnis für das Interessengebiet zu erlangen. Basierend auf einer Literaturrecherche erfolgt die Beschreibung der Ausgangssituation des Forschungsziels. (BLESSING & CHAKRABARTI 2009).

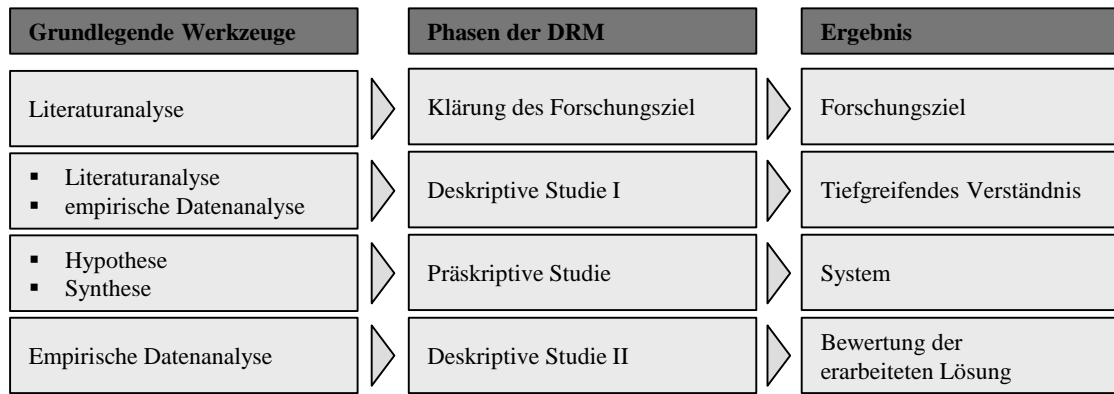


Abbildung 1-5: Forschungsmethodische Vorgehen nach BLESSING & CHAKRABARTI (2009)

Durch die vorhergehenden Abschnitte wurden die für die vorliegende Arbeit relevante Ausgangssituation, Motivation und Zielsetzung definiert. In Abbildung 1-6 ist die Zuordnung der unterschiedlichen Phasen der DRM zu den Kapiteln der vorliegenden Arbeit dargestellt.

Nach der Klärung des Forschungsziels wird im zweiten Schritt der DRM – der Deskriptiven Studie I – eine terminologisch-deskriptive Untersuchung zur Ableitung der Handlungsbedarfe sowie der Systemanforderungen durchgeführt (BLESSING & CHAKRABARTI 2009). Das Kapitel 2 dient dazu, Erkenntnisse zu den identifizierten Themengebieten PPS, RL und Erklärbarkeit von systemischen Entscheidungen zu gewinnen (siehe Abbildung 1-6). Anschließend gilt es, ausgehend von den identifizierten Defiziten, den Handlungsbedarf abzuleiten.

Für die Präskriptive Studie – den dritten Schritt der DRM – wird ein analytisch-deduktives Forschungsvorgehen gewählt. Hierbei wird ein Ansatz entwickelt, welcher die in der Deskriptiven Studie I identifizierten Defizite adressiert und zu deren Mitigation führt. Als grundlegendes Werkzeug in dieser Phase kann das Aufstellen neuer Hypothesen oder die Synthese bereits bestehender Ansätze dienen. Zur Verbesserung der Ausgangssituation wird ein lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung entwickelt. Basierend auf den identifizierten Anforderungen erfolgt in Kapitel 3 die initiale Beschreibung der unterschiedlichen Elemente des Systems. Kapitel 4 zeigt, wie ein benutzerrollenspezifisches Informationsmodell im Kontext der Produktionssteuerung erstellt werden kann. Ausgehend vom entwickelten Referenzmodell sowie der Kategorisierung des Unterstützungsbedarfs der Mitarbeiter wird das methodische Vorgehen zur unternehmensspezifischen Adaption erläutert. Auf Basis des Informationsmodells erfolgt im Rahmen von Kapitel 5 die Entwicklung des lernenden Systems

zur Produktionssteuerung. Anschließend wird in Kapitel 6 ein Modul zur Erklärung von systemischen Entscheidungen entwickelt. Hierfür werden unterschiedliche Arten von Erklärungen realisiert. Abschließend erfolgt die Integration in das lernende System zur Produktionssteuerung.

Den Abschluss der vorliegenden Arbeit bildet die Deskriptive Studie II. Das gewählte empirisch-induktive Vorgehen der Deskriptiven Studie II hat das Ziel, die prinzipielle Funktionsfähigkeit des entwickelten Systems nachzuweisen und zu bewerten. Dies erfolgt in der vorliegenden Arbeit im Rahmen der technischen Umsetzung in Kapitel 7. Ausgehend von einem realen Anwendungsfall, wird das lernende und erklärbare System implementiert und angepasst. Die Kapitel 8 und 9 schließen die Arbeit mit einer kritischen Würdigung des Systems, der Zusammenfassung der wichtigsten Erkenntnisse sowie einem Ausblick auf weiterführende Forschungsarbeiten ab.

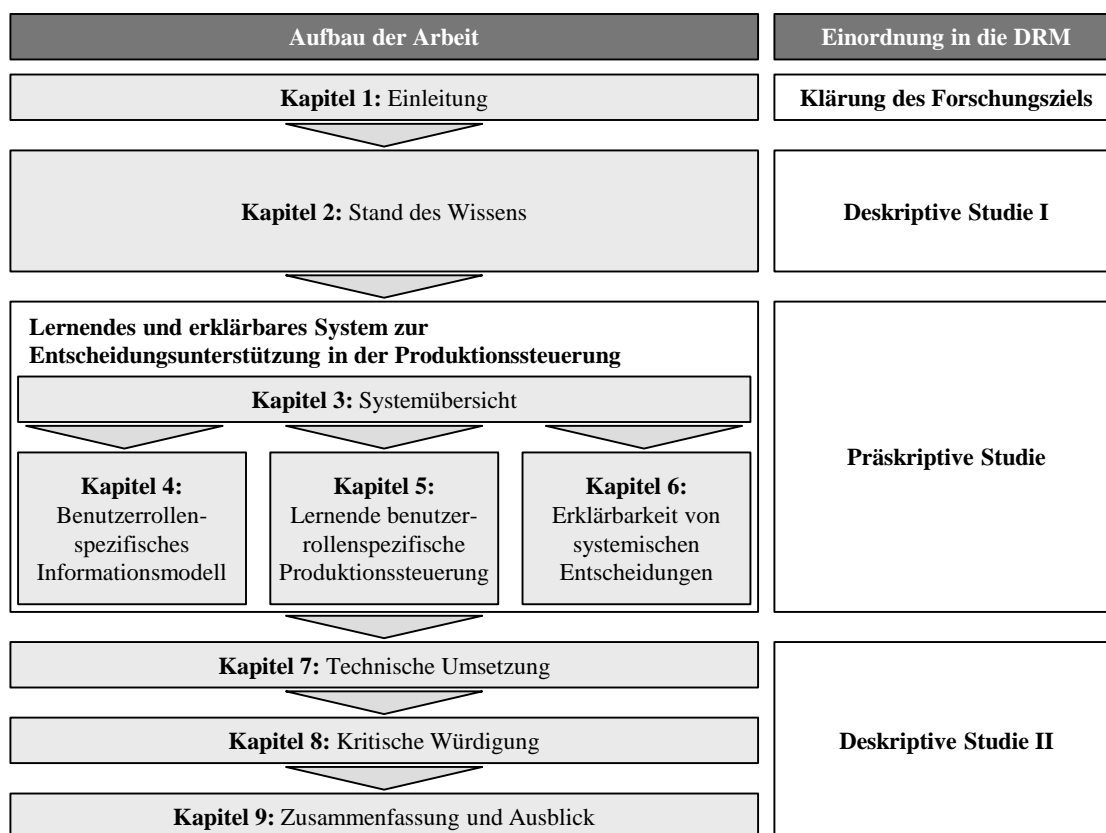


Abbildung 1-6: Aufbau der Arbeit und Einordnung in die DRM

2 Stand des Wissens

2.1 Allgemeines

Das Kapitel 2 dieser Arbeit beinhaltet die *Deskriptive Studie I* der DRM. Dabei werden die im Rahmen der ersten Phase der DRM (Klärung des Forschungsziels) identifizierten Themengebiete (siehe Abschnitte 1.1 und 1.2) terminologisch-deskriptiv untersucht. Hierdurch werden die für diese Arbeit relevanten wissenschaftlichen Grundlagen gelegt.

Zuerst erfolgt eine allgemeine Beschreibung der Produktion (siehe Abschnitt 2.2). Abschnitt 2.3 behandelt anschließend die Grundlagen der PPS. Dies beinhaltet das Zielsystem der PPS, die Grundlagen der Produktionssteuerung, unterschiedliche Ansätze zur Produktionssteuerung sowie das Daten- und Informationsmanagement. Die für diese Arbeit relevanten Agenten und Agentensysteme werden in Abschnitt 2.4 vorgestellt. In Abschnitt 2.5 werden die Grundlagen des RL erörtert. Erklärbarkeitsansätze im Kontext von durch Computersysteme im Allgemeinen und ML im Speziellen vorgeschlagenen bzw. getroffenen Entscheidungen werden in Abschnitt 2.6 dargestellt. Im Anschluss werden die Grundlagen der Entscheidungstheorie vorgestellt (siehe Abschnitt 2.7). Den Abschluss des Kapitels bildet die konsequente Ableitung des Handlungsbedarfs aus dem analysierten Stand der Forschung und Technik (siehe Abschnitt 2.8).

2.2 Begriffsbestimmung

Produktion beschreibt den „*betriebliche(n) Umwandlungs- und Transformationsprozess, durch den aus den Einsatzgütern andere Güter oder Dienstleistungen erstellt werden*“ (WEBER & KABST 2006). Die im industriellen Umfeld zur Erstellung der Güter und Dienstleistungen notwendigen Systeme gilt es nach SCHMIDTKE (1976) und dem Verband für Arbeitsgestaltung, Betriebsorganisation und Unternehmensentwicklung e. V. [REFA] (REFA 1984) in drei Subsysteme – das soziale System, das technische System und das soziotechnische System – zu unterscheiden. In einem sozialen System findet die Interaktion zwischen Menschen statt. Mögliche Ausprägungen sind Projektteams oder Betriebsversammlungen. Bei einem technischen System interagieren Betriebsmittel miteinander (z. B. eine Transferstraße). (SCHMIDTKE 1976, REFA 1984) Ein soziotechnisches System besteht aus einer sozialen Teilkomponente – bspw. Mitglieder und deren Rolle in

einer Gruppe – sowie einer technischen Teilkomponente – bspw. Aufgaben und Technologien. Zur Erzielung eines spezifischen Ergebnisses ist eine Wechselbeziehung zwischen beiden Komponenten erforderlich. Damit das bestmögliche Resultat erreicht werden kann, ist eine gemeinsame Optimierung der Teilsysteme notwendig. (TRIST 1981)

Das Ziel von produzierenden Unternehmen ist es, die vom Kunden gewünschten Produkte in der geforderten Menge und gewünschten Qualität zum richtigen Zeitpunkt zu liefern (WIENDAHL & WIENDAHL 2019). Hierbei ist es die zentrale Aufgabe der PPS, unter Berücksichtigung sowohl wirtschaftlicher als auch terminlicher Restriktionen die Fertigungs- und Montageprozesse zu steuern (EVERSHEIM 2002). Laut dem Verband Deutscher Ingenieure e. V. (VDI) (1992) wird die Produktionsplanung als „*systematisches Suchen und Festlegen von Zielen für die Produktion, Vorbereiten von Produktionsaufgaben und Festlegung des Ablaufes zum Erreichen dieser Ziele*“ definiert. Die Produktionssteuerung ist nach VDI (1992) als das „*Veranlassen, Überwachen und Sichern der Durchführung der Produktionsaufgaben hinsichtlich Bedarf (Menge und Termin), Qualität und Kosten und Arbeitsbedingungen*“ definiert.

Ein wesentliches Kriterium für eine erfolgreiche Erfüllung der Aufgaben der PPS und dadurch für den wirtschaftlichen Erfolg eines Unternehmens, ist die Interaktion zwischen dem Menschen und den technischen Systemen (NYHUIS & GERST 2008). Eine geringe Akzeptanz der Planung von PPS-Systemen kann, bspw. durch eine manuelle Übersteuerung derselben, die Wirtschaftlichkeit des Unternehmens stark beeinflussen.

2.3 Produktionsplanung und -steuerung

2.3.1 Zielsystem der Produktionsplanung und -steuerung

Das logistische Zielsystem der PPS beschreibt den Einfluss der Produktion auf das Unternehmensziel der hohen Wirtschaftlichkeit (NYHUIS & WIENDAHL 2012). Es besteht aus den zwei Säulen *Logistikleistung* und *Logistikkosten* (siehe Abbildung 2-1). Hierbei wird die Logistikleistung, bestehend aus Lieferzeit und Liefertreue, insbesondere durch die Marktseite perzipiert und sollte möglichst hoch sein. Hingegen sollten die Logistikkosten, bestehend aus Prozesskosten für die Auftragsabwicklung und Kapitalbindungskosten, aus Unternehmenssicht möglichst gering

sein. Die gleichzeitige Verbesserung der Logistikleistung und -kosten birgt allerdings einen Zielkonflikt. (WIENDAHL & WIENDAHL 2019) Dieser Zielkonflikt zwischen den Zielgrößen der PPS wird auch als *Dilemma der Ablaufplanung* bezeichnet (GUTENBERG 1971). Hierbei steht das Streben eines Unternehmens nach einer hohen Auslastung der Produktion und somit nach niedrigen Prozesskosten auf der einen Seite. Auf der anderen Seite steht das Streben nach einem niedrigen Bestandsniveau, kurzen Durchlaufzeiten und einer hohen Termintreue, um niedrige Kapitalbindungskosten zu realisieren sowie die Kundenforderung nach einer hohen Liefertreue verbunden mit einer geringen Lieferzeit zu erfüllen. (WIENDAHL & WIENDAHL 2019, SCHMIDT & NYHUIS 2021a) Aufgrund der Gegenläufigkeit der logistischen Zielgrößen ist die isolierte Betrachtung einer Zielgröße sowie der Initiierung von Maßnahmen zu deren Verbesserung unter dem Aspekt der Wirtschaftlichkeit nicht zielführend. Zur Verbesserung der Wirtschaftlichkeit eines Unternehmens gilt es die Auswirkungen von Maßnahmen auf alle Zielgrößen zu berücksichtigen (NYHUIS & WIENDAHL 2012). Eine Reduzierung der internen Durchlaufzeit kann bspw. durch eine Erhöhung der Kapazität (Personal- und/oder Maschinenkapazität) erzielt werden. Dies reduziert allerdings die Auslastung und führt damit zu höheren Prozesskosten. Somit erfolgt eine positive Beeinflussung der Logistikleistung zulasten der Logistikkosten. (NYHUIS & WIENDAHL 2012) Ein weiterer Zielkonflikt besteht zwischen den Zielgrößen Bestand und Auslastung. Eine hohe Auslastung reduziert die Prozesskosten, kann allerdings nur durch ein entsprechendes Bestandsniveau erzielt werden. Das erforderliche Bestandsniveau hat höhere Bestände zu Folge, was das Ziel der Minimierung der Bestände konterkariert. (NYHUIS & SCHMIDT 2008)

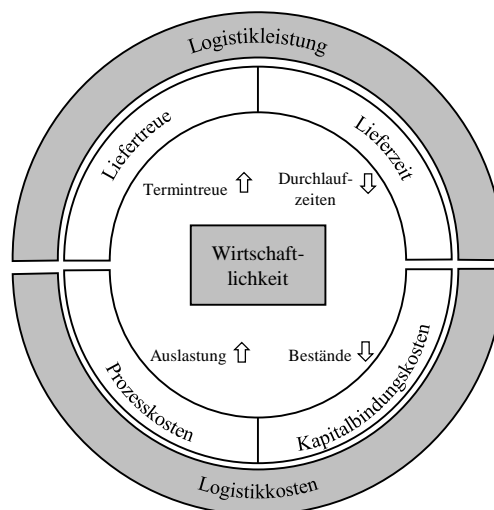


Abbildung 2-1: Logistische Zielsystem der Produktionsplanung und -steuerung (i. A. an WIENDAHL & WIENDAHL 2019)

Entsprechend dem Unternehmen und den spezifischen Kundenanforderungen erfolgt i. d. R. eine unternehmensspezifische Gewichtung der Zielgrößen. Durch diese Möglichkeit der Adaption des Zielsystems kann jedes Unternehmen seine eigene strategische Ausrichtung bei den Entscheidungen im Rahmen der PPS berücksichtigen.

2.3.2 Aufgaben der Produktionsplanung und -steuerung

Die PPS nimmt durch das Ausführen unterschiedlicher Aufgaben direkten Einfluss auf die im vorherigen Abschnitt vorgestellten Zielgrößen. Das Aachener PPS-Modell unterscheidet hierbei zwischen *Netzwerkaufgaben*, *Kernaufgaben* sowie *Querschnittsaufgaben* (siehe Abbildung 2-2). Netzwerkaufgaben beinhalten planende Aufgaben mit Netzwerkbezug. Dazu gehören die strategische Auslegung der Netzwerkkonfiguration, die Netzwerkabsatzplanung und die Netzwerkbedarfsplanung. Kernaufgaben fokussieren die unternehmensinternen Aufgaben des Produkterstellungsprozesses. Querschnittsaufgaben beinhalten sowohl Bestandteile von Kern- als auch Netzwerkaufgaben und haben einen koordinierenden Charakter zwischen beiden. Die Querschnittsaufgaben umfassen das Auftragsmanagement, das Bestandsmanagement und das Controlling. (SCHUH ET AL. 2012b)

Aufgrund der untergeordneten Relevanz der Netzwerk- und Querschnittsaufgaben für diese Arbeit werden diese im Folgenden nicht weiter betrachtet. Es sei an dieser Stelle allerdings auf SCHUH & STICH (2012) für eine ausführliche Beschreibung

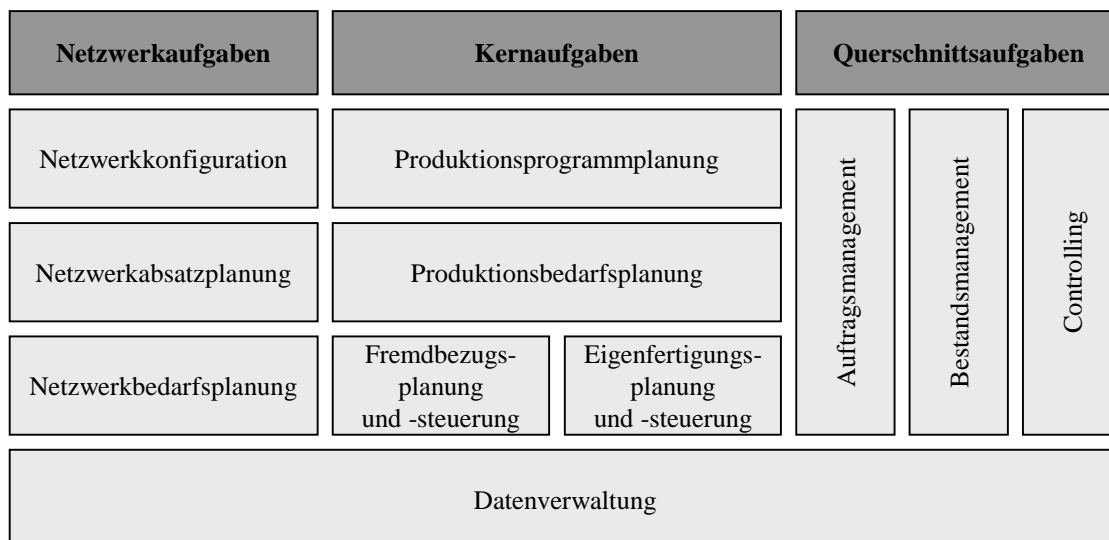


Abbildung 2-2: Aufgabensicht des Aachener PPS-Modells (SCHUH ET AL. 2012b)

verwiesen. Die Kernaufgaben werden in *Produktionsprogrammplanung*, *Produktionsbedarfsplanung*, *Fremdbezugsplanung* und *-steuerung* sowie *Eigenfertigungsplanung* und *-steuerung* gegliedert. Die *Produktionsprogrammplanung* hat die Aufgabe, die zu fertigenden Produkte für einen bestimmten Zeitraum in Abhängigkeit von den tatsächlich angefragten oder prognostizierten Kundenbedarfen festzulegen (HACKSTEIN 1989). Aufbauend auf dem Produktionsprogramm bestimmt die *Produktionsbedarfsplanung* die mittelfristig notwendigen Ressourcen, um die Ausführbarkeit des Produktionsprogramms zu gewährleisten. Das Resultat ist das Eigenfertigungsprogramm. Dieses legt den Plan-Abgang der Produktion grob fest. Anschließend erfolgt die Spezifizierung des Eigenfertigungsprogramms im Rahmen der *Eigenfertigungsplanung* und *-steuerung*. Hierbei gilt es unterschiedliche Randbedingungen (z. B. verfügbare Kapazitäten) zu berücksichtigen, um einen durchführbaren Produktionsplan zu erstellen. Unteraufgaben der Eigenfertigungsplanung und -steuerung sind die Losgrößenrechnung, Feinterminierung, Ressourcenfeinplanung, Reihenfolgeplanung, Verfügbarkeitsprüfung und die Auftragsfreigabe. (SCHUH ET AL. 2012a, SCHMIDT & NYHUIS 2021b)

Die in der Datenverwaltung gespeicherten und gepflegten Daten werden in den Netzwerk-, Kern- und Querschnittsaufgaben verwendet. Ziel der Datenverwaltung ist es, die für die Ausführung der Aufgaben notwendigen Daten mit einer hohen Datenqualität zur Verfügung zu stellen. Da sie somit die Grundlage für ein erfolgreiches Ausführen der genannten Aufgaben bildet, kommt ihr eine zentrale Rolle innerhalb der PPS zu. (SCHUH ET AL. 2012b)

2.3.3 Modell der Fertigungssteuerung

Die Kernaufgabe der Produktionssteuerung – im Aachener PPS-Modell als *Eigenfertigungssteuerung* bezeichnet – ist die Ausführung des vorab entworfenen Produktionsplans. Hierfür kann im Rahmen der Produktionssteuerung zwischen unterschiedlichen Aufgaben differenziert werden. Die Realisierung dieser Aufgaben hat einen signifikanten Einfluss auf den wirtschaftlichen Erfolg eines Unternehmens (NYHUIS & WIENDAHL 2012). LÖDDING (2016) verdeutlicht anhand seines qualitativen Wirkmodells der Fertigungssteuerung diesen Zusammenhang zwischen den Aufgaben der Produktionssteuerung und den Zielgrößen der Produktionslogistik (siehe Abbildung 2-3). Es erfolgt eine Differenzierung zwischen *Aufgaben* und den daraus resultierenden *Stellgrößen*. Die Differenz zwischen zwei Stellgrößen entspricht der *Regelgröße*. Eine Veränderung der Regelgröße hat wiederum einen direkten Einfluss auf die Zielgrößen. (LÖDDING 2016)

Der Produktionsplanung ist die Aufgabe der *Auftragserzeugung* mit den zugehörigen Stellgrößen *Plan-Zugang*, *Plan-Abgang* und *Plan-Reihenfolge* zuzuordnen. Über diese Stellgrößen werden der planmäßige Zugang, der Abgang sowie die planmäßige Reihenfolge bestimmt (LÖDDING 2016). Im Rahmen dieser Arbeit ist insbesondere die Produktionssteuerung von Relevanz, weshalb die Produktionsplanung nicht tiefergehend beschrieben wird. Für eine detaillierte Auseinandersetzung mit der Produktionsplanung sei auf SCHUH & STICH (2012), WIENDAHL & WIENDAHL (2019) und SCHMIDT & NYHUIS (2021b) verwiesen. Im weiteren Verlauf des Abschnitts werden somit die Aufgaben der Produktionssteuerung detailliert beschrieben.

Die Produktionssteuerung wird durch die Aufgaben *Auftragsfreigabe*, *Kapazitätssteuerung* und *Reihenfolgebildung* charakterisiert. Durch die *Auftragsfreigabe*, welche sowohl den Zeitpunkt als auch die Reihenfolge der Freigabe der Aufträge zur Fertigung bestimmt, wird der *Ist-Zugang* zur Produktion geregelt. Der *Ist-Abgang* wird hingegen durch die *Kapazitätssteuerung* festgelegt. Durch die *Reihenfolgebildung* wird die Reihenfolge festgelegt, in welcher die unterschiedlichen Aufträge abgearbeitet werden. (LÖDDING 2016)

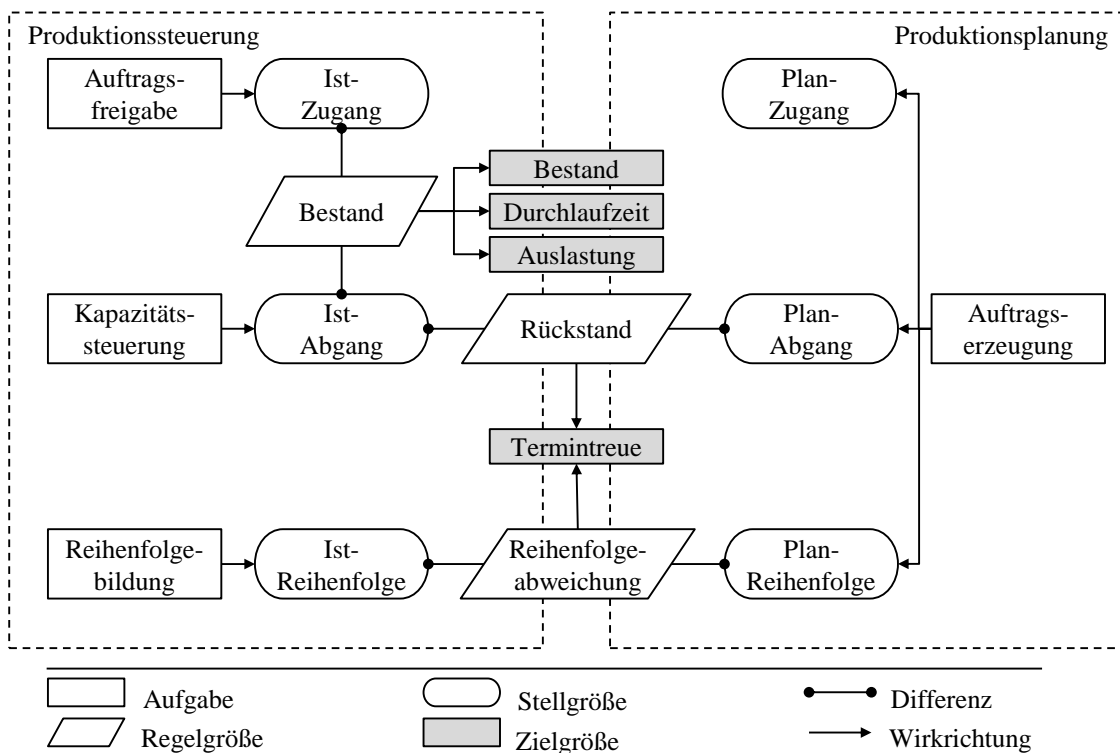


Abbildung 2-3: Modell der Fertigungssteuerung (i. A. an LÖDDING 2016)

Aufgabe der Auftragsfreigabe

Abbildung 2-4 zeigt unterschiedliche Charakteristika der Auftragsfreigabe, durch welche sich unterschiedliche Verfahren derselben differenzieren. Durch das *Kriterium* der Auftragsfreigabe wird festgelegt, unter welchen Randbedingungen ein Auftrag freigegeben wird. Das Kriterium kann vier unterschiedliche Ausprägungen haben. Die Auftragsfreigabe kann sofort nach der Auftragserzeugung erfolgen. Eine andere Möglichkeit besteht darin, einen Auftrag erst freizugeben, sobald der Plan-Starttermin erreicht ist. Alternativ kann die Freigabe der Aufträge an den Bestand der Fertigung oder die Belastung von Arbeitsbereichen gekoppelt werden. (LÖDDING 2016) Für eine genauere Beschreibung der unterschiedlichen Verfahren zur Auftragsfreigabe (z. B. Conwip-Steuerung, belastungsorientierte Auftragsfreigabe) sei auf LÖDDING (2016) verwiesen.

Der *Detaillierungsgrad* beschreibt die Art und Weise, auf welche der Auftrag freigegeben wird. Besonders relevant ist der Detaillierungsgrad der Auftragsfreigabe für die bestandsregelnden Verfahren. Prinzipiell sind drei Ausprägungen möglich. Zuerst kann die Auftragsfreigabe für alle Arbeitsvorgänge erfolgen (*zentrale* Bestandregelung). Somit ist der gesamte Auftrag auf einmal freigegeben. Alternativ kann die Auftragsfreigabe so konzeptioniert sein, dass für jeden Arbeitsschritt eine Freigabe erforderlich ist (*dezentrale* Bestandregelung). Die dritte Ausprägung erfordert einerseits die Freigabe des Auftrags und andererseits die Freigabe an jedem Arbeitssystem. Diese *hybride* Art der Auftragsfreigabe erweitert die dezentrale Auftragsfreigabe um die initiale Auftragsfreigabe, welche den Bestand im Gesamtsystem berücksichtigt. (LÖDDING 2016)

Die *Auslösungslogik* spezifiziert den Zeitpunkt, zu welchem neue Aufträge freigegeben werden. Dies kann einerseits bedeuten, dass dies *periodisch* erfolgt und die Aufträge ausschließlich zum im Vorhinein definierten Zeitpunkt freigegeben wer-

Auftragsfreigabe	Sofort	Plan-Starttermin	Bestandsregelnde Verfahren	Belastungsorientierte Verfahren
Detaillierungsgrad	Zentral	Dezentral		Hybrid
Auslösungslogik	Periodisch		Ereignisorientiert	

Abbildung 2-4: Mögliche Ausprägungen der Auftragsfreigabe (i. A. an LÖDDING 2016)

den. Andererseits kann die Freigabe *ereignisorientiert* erfolgen. Hier löst das Eintreten eines definierten Ereignisses (z. B. das Unterschreiten einer Bestandsgrenze) die Auftragsfreigabe aus. (BERGAMASCHI ET AL. 1997, LÖDDING 2016)

Aufgabe der Kapazitätssteuerung

Die Kapazitätssteuerung bestimmt den realen Einsatz der verfügbaren Kapazitäten. Durch deren Festlegung wird der Ist-Abgang des Produktionssystems bestimmt. Verfahren zur Kapazitätssteuerung lassen sich anhand der Charakteristika *Kriterium der Kapazitätssteuerung*, *Detailierungsgrad* und *Auslösungslogik* beschreiben. Das Kriterium der Kapazitätssteuerung bestimmt die Art und Weise, wie Unternehmen Entscheidungen über Maßnahmen zur Kapazitätssteuerung treffen. Übergeordnet verfolgen die Maßnahmen entweder das Ziel der Erfüllung des Kundenbedarfs bzw. der Planungsvorgaben oder der Koordination der Kapazitäten der Arbeitssysteme. Der Detaillierungsgrad der Kapazitätssteuerung kann entweder die Ausprägung *grob* – für das gesamte Produktionssystem – oder *fein* – für ausgewählte Arbeitssysteme – annehmen. Ebenso wie bei der Auftragsfreigabe können Maßnahmen der Kapazitätssteuerung entweder periodisch oder ereignisbasiert ausgelöst werden. (LÖDDING 2016) Für konkrete Verfahren zur Kapazitätssteuerung (z. B. Rückstandsregelung, planorientierte Kapazitätssteuerung) sei auf LÖDDING (2016) verwiesen.

Aufgabe der Reihenfolgebildung

Ziel der Verfahren zur Reihenfolgebildung ist die Erhöhung der Liefertreue. Die Reihenfolgebildung bestimmt die Ist-Reihenfolge und beeinflusst damit direkt die Regelgröße *Reihenfolgeabweichung*. Über diese Regelgröße hat die Reihenfolgebildung einen großen Einfluss auf die Termintreue. Zur Reihenfolgebildung werden Prioritäten an in einer Warteschlange befindliche Aufträge zugewiesen. Entsprechend dieser Priorität werden Aufträge anschließend abgearbeitet. Heuristiken, welche einen positiven Einfluss auf die Liefertreue haben, sind FIFO, frühester Plan-Starttermin (FPS), frühester Plan-Endtermin (FPE) sowie geringster Restschlupf. Verfahren zur Erhöhung der Leistung sind rüstzeitoptimierende Reihenfolgebildungsverfahren. Ziel dieser Art von Verfahren ist es, unnötige Formatwechsel oder ggf. Reinigungszeiten durch eine geeignete Reihenfolge der Aufträge zu vermeiden. (LÖDDING 2016)

Die Einhaltung der Plan-Reihenfolge hat einen erheblichen Einfluss auf die logistische Zielgröße der Termintreue und ist somit von zentraler Relevanz. Eine geringe Einhaltung der Plan-Reihenfolge kann bspw. bedeuten, dass Mitarbeiter die

Ist-Reihenfolge unabhängig von den definierten Unternehmenskriterien bzw. den definierten logistischen Zielgrößen festlegen. Im schlimmsten Fall kann der Verstoß gegen die Plan-Reihenfolge an einem Arbeitssystem zu einem Materialflussabriss an einem nachgelagerten Arbeitssystem führen. Zur Quantifizierung der Einhaltung der Plan-Reihenfolge kann die Reihenfolgedisziplin verwendet werden. Die Reihenfolgedisziplin berechnet sich nach LÖDDING (2016) zu

$$RD = \frac{\text{AnzAVG mit AnzÜA}}{\text{AnZAVG}} \times 100 \quad (1)$$

mit RD Reihenfolgedisziplin [%],
 AnzAVG Anzahl Arbeitsvorgänge [-] und
 AnzÜA Anzahl übergangener Aufträge [-].

Grundlage für das effektive und effiziente Durchführen der unterschiedlichen Aufgaben der Produktionssteuerung sind die verfügbaren Daten (z. B. Rückmeldedaten aus der Produktion) und Informationen. Aufgrund deren Relevanz erfolgt im folgenden Abschnitt eine detaillierte Betrachtung des Daten- und Informationsmanagements.

2.3.4 Daten- und Informationsmanagement

Der informationstheoretische Ansatz zur Beschreibung des Zusammenhangs von Zeichen, Daten, Informationen und Wissen wird in Abbildung 2-5 gezeigt. Daten ergeben sich durch die Verwendung einer definierten Syntax – einer geordneten Struktur – aus Zeichen. Durch einen entsprechenden Kontext ergeben sich aus den Daten Informationen. Vernetzte Informationen werden als Wissen bezeichnet. (REHÄUSER & KRCMAR 1996, BODENDORF 2006) Somit basieren sowohl Informationen als auch Wissen auf Daten (KRCMAR 2015). In der Produktion werden Daten bspw. durch Sensoren erzeugt. Auch Rückmeldungen zum aktuellen Status von Ressourcen, Aufträgen und Beständen können den Daten zugerechnet werden.

Die Verarbeitung der Daten erfolgt i. d. R. computergestützt, damit die wachsende Datenmenge beherrscht und effizient sowie zielgerichtet genutzt werden kann. Für die Verarbeitung der Daten und die Bereitstellung der Informationen haben sich unterschiedliche (Informations-)Systeme mit unterschiedlichen Charakteristika etabliert. Anhand der Kriterien *Ebenen*, *Aufgaben* und *Zeithorizont* kann eine übergeordnete Einteilung dieser Systeme erfolgen. (KLETTI 2015a, VDI 5600-1)

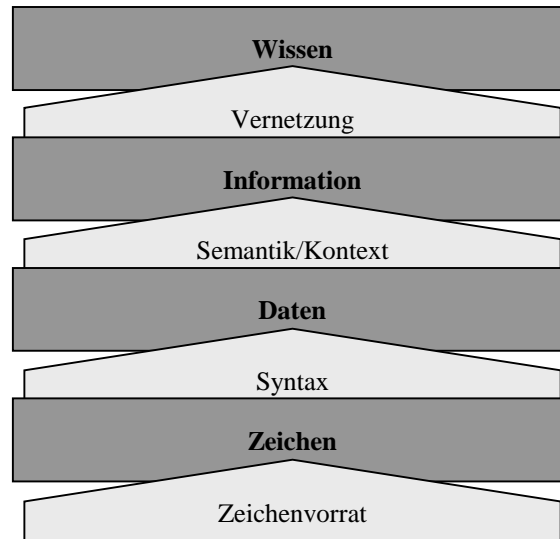


Abbildung 2-5: Zusammenhang zwischen Zeichen, Daten, Informationen und Wissen (i. A. an BODENDORF 2006)

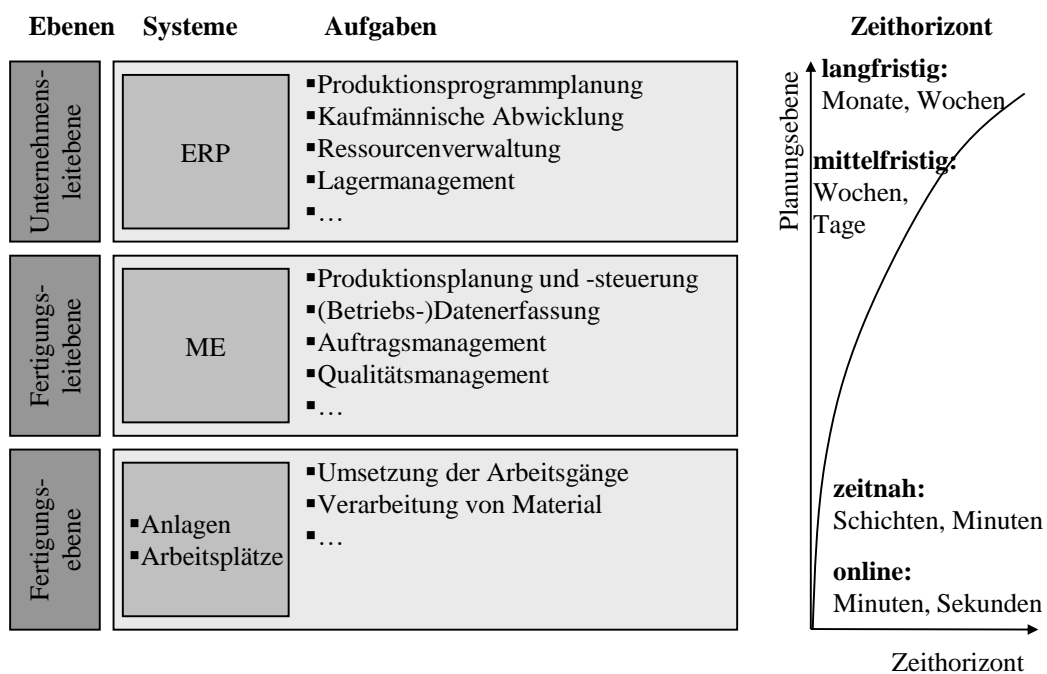
Zwischen Informationssystemen und Nutzern erfolgt eine Interaktion zur Erfüllung von spezifischen Aufgaben, weshalb Informationssysteme den soziotechnischen Systemen zuordenbar sind. Dieser Ansatz „beruht auf der Annahme, dass Betriebe aus technologischen und sozialen Teilsystemen bestehen und dass es im Interesse der Wirtschaftlichkeit darauf ankommt, beide Systeme aufeinander abzustimmen.“ (NYHUIS & GERST 2008)

Abbildung 2-6 zeigt die Einordnung unterschiedlicher produktionsnaher IT-Systeme zur Erfüllung der Aufgaben der PPS in die Unternehmensebenen sowie den relevanten Zeithorizont. Das ERP-System ist der Unternehmensleitebene zuordenbar. Charakteristisch ist ein lang- bis mittelfristiger Planungshorizont, sodass es sich um ein tendenziell starres System handelt. Aufgabe des ERP-Systems ist es, Soll-Vorgaben (z. B. geforderter Liefertermin, Mengenbedarf) zu definieren, auf deren Basis Fertigungsaufträge erzeugt werden. Diese werden anschließend an die Produktion übergeben. Ziel der Produktion ist es, die Vorgabewerte zu erfüllen. (KLETTI 2015a, VDI 5600-1, KLETTI & DEISENROTH 2021)

Für die Steuerung der Fertigung ist eine detailliertere Granularitätsstufe notwendig, als sie ERP-Systeme mit ihrer lang- bis mittelfristigen Ausrichtung bieten. Diese Anforderungen werden durch das MES erfüllt. (NIEHUES ET AL. 2017) Das MES ist auf der Fertigungsleitebene angesiedelt und zeichnet sich durch einen kurzfristigen Planungshorizont aus. Der relevante Zeithorizont umfasst hierbei Tage bzw. Schichten. Dem MES sind u. a. die Aufgaben der Datenerfassung, der

Leistungsanalyse und der Produktionsplanung und -steuerung zuordenbar. (VDI 5600-1, KLETTI & DEISENROTH 2021)

Die Qualität der Daten ist von zentraler Bedeutung für die erfolgreiche Ausführung der Aufgaben der PPS (REUTER & BRAMBRING 2016, ANDERS ET AL. 2021). Eine niedrige Datenqualität kann sich einerseits durch fehlerbehaftete Daten (z. B. falsche Vorgabezeiten für die Fertigstellung eines Auftrags) und andererseits durch fehlende Daten (z. B. keine Rückmeldung über die Fertigstellung eines Auftrags) äußern. Werden Daten niedriger Qualität als Ausgangsbasis für die Produktionssteuerung verwendet, wird das Treffen von Entscheidungen zur erfolgreichen Umsetzung der Produktionssteuerung in dem bereits mit Unsicherheiten behafteten Feld weiter erschwert. (REUTER & BRAMBRING 2016) Die erfolgreiche Verwertung von Daten (insbesondere der Rückmeldedaten) kann dem Unternehmen allerdings durch die Verbesserung der logistischen Leistungsfähigkeit ein Differenzierungsmerkmal bieten (WIENDAHL 2008).



Legende:

ERP: Enterprise Resource Planning

ME: Manufacturing Execution

Abbildung 2-6: Charakterisierung von PPS-Systemen nach Ebene, System, Aufgabe und Zeithorizont (i. A. an KLETTI 2015a, VDI 5600-1)

Die Organisationsstruktur und das Informationsmanagement sind eng miteinander verzahnt. Erstere definiert die Distribution der Steuerungs- und Entscheidungskompetenzen. In Abhängigkeit von der Verteilung der genannten Kompetenzen gilt es den Informationsfluss innerhalb der Organisation zu gestalten, damit die Wirtschaftlichkeit verbessert werden kann. (BONGAERTS ET AL. 2000) Im Kontext der PPS führen inkonsistente Steuerungs- und Entscheidungskompetenzen, unklare Prozesse oder Schnittstellen – und daraus resultierend ein gestörter Informationsfluss – zu einer dysfunktionalen PPS (WIENDAHL 2011). Die Entscheidungsgrundlage für eine leistungsfähige PPS bilden die „(r)ichtigen Informationen in der richtigen Form zur richtigen Zeit am richtigen Ort“ (NYHUIS ET AL. 2017).

Abbildung 2-7 zeigt eine Übersicht über die Steuerungsstrukturen von Unternehmen. Der Fokus liegt dabei insbesondere auf der Distribution der Steuerungs- und Entscheidungskompetenzen. Einerseits kann eine Unterscheidung zwischen einer *zentralen, dezentralen* und *autonomen Steuerung* von Unternehmen vorgenommen werden. Handelt es sich um eine zentrale Organisationsstruktur, so werden alle Daten zentral abgespeichert und die Informationsverarbeitung erfolgt ebenfalls

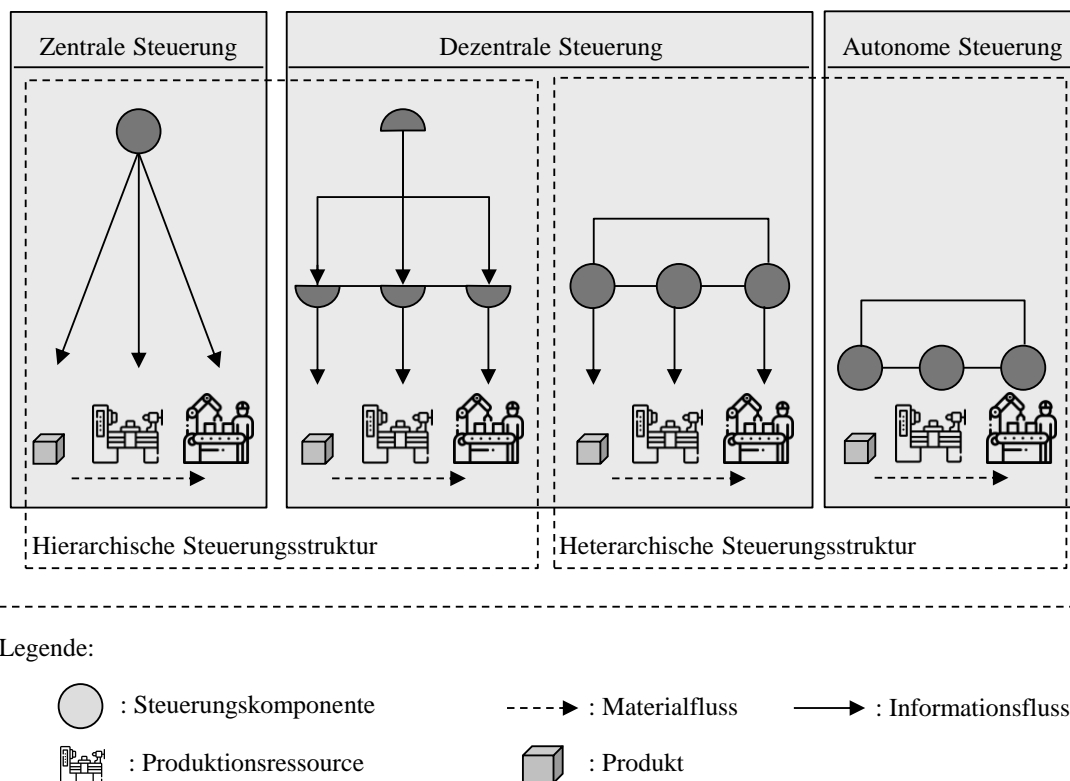


Abbildung 2-7: Überblick über unterschiedliche Organisationsstrukturen (i. A. an SCHOLZ-REITER & FREITAG 2007, ENGELHARDT 2015)

zentral (SCHOLZ-REITER & FREITAG 2007). Der Informationsfluss verläuft typischerweise hin zur zentralen Steuereinheit, wohingegen der Kommunikationsweg top-down verläuft. Die unterschiedlichen Produktionsbereiche besitzen dementsprechend ausschließlich eine exekutive Funktion. (BONGAERTS ET AL. 2000, OSTGATHE 2012) Vorteile dieser Organisationsstruktur sind u. a. die konsistente Datenbasis für alle Entscheidungen sowie die Möglichkeit, eine globale Optimierung durchzuführen. (SCHOLZ-REITER & FREITAG 2007) Es handelt sich hierbei um ein hierarchisches System, welches i. d. R. nur schwer erweiterbar und dessen Reaktionsfähigkeit auf unvorhergesehene Ereignisse eingeschränkt ist. (BONGAERTS ET AL. 2000)

Bei der Kombination von hierarchischer Steuerungsstruktur und dezentralen Steuerungskomponenten erfolgt prinzipiell eine vertikale Segmentierung des Entscheidungsproblems. Hierdurch wird die Entscheidungscomplexität der zentralen Instanz reduziert. Dies bedingt allerdings deren Zunahme auf der Ebene der dezentralen Instanzen. Durch diese Ausprägung der Organisationsstruktur werden die Vorteile der dezentralen und zentralen Organisationsstruktur miteinander verknüpft. Es kann eine hohe Reaktionsfähigkeit auf unvorhergesehene Ereignisse bei gleichzeitiger Optimierung der Leistung des Gesamtsystems realisiert werden. (BONGAERTS ET AL. 2000, OSTGATHE 2012) Allerdings bedingt der Einsatz von zwei Steuerungssystemen eine höhere systemseitige Komplexität. Einerseits ist es notwendig, eine geeignete Segmentierung der Aufgaben in Teilaufgaben zu realisieren. Andererseits muss der für diese Organisationsstruktur höhere Kommunikations- und Koordinationsaufwand abgebildet werden.

Die heterarchische Steuerungsstruktur und dezentrale Steuerung hingegen besitzt keine zentralen, sondern besteht ausschließlich aus dezentralen Steuerungskomponenten (BONGAERTS ET AL. 2000). Die Aufgabe des Gesamtsystems wird in Teilaufgaben zerlegt. Somit hat jede Organisationseinheit eigene Verantwortlichkeiten und Entscheidungskompetenzen. Charakteristisch für die dezentrale Organisationsstruktur sind ein hoher Grad an Flexibilität, eine im Vergleich zur zentralen Organisationsstruktur niedrigere Entscheidungscomplexität sowie eine hohe Robustheit im Falle eines unvorhergesehenen Ereignisses. (BONGAERTS ET AL. 2000, OSTGATHE 2012) Aufgrund der Dezentralität ist allerdings die Vorhersagbarkeit des Verhaltens des Gesamtsystems gering. (BONGAERTS ET AL. 2000) Bei der autonomen Steuerung wird weiterhin auf eine dezidierte Steuerungskomponente verzichtet. Die Kommunikation und Steuerung erfolgt mittels intelligenter Maschinen und Produkte (SCHOLZ-REITER & FREITAG 2007).

Ausgehend vom grundlegenden Zusammenhang zwischen Daten, Informationen und Wissen konnten die wichtigen Charakteristika von Informationssystemen im Produktionsumfeld aufgezeigt werden. Dies beinhaltet einerseits die Beschreibung unterschiedlicher PPS-Systeme anhand verschiedener Unternehmensebenen, Aufgaben und der relevanten Zeithorizonte. Andererseits konnten unterschiedliche mögliche Organisationsstrukturen gezeigt werden, welche für den weiteren Verlauf der Arbeit von Bedeutung sind.

2.3.5 Adaptive Ansätze zur Produktionssteuerung

In diesem Abschnitt werden adaptive Ansätze zur Produktionssteuerung vorgestellt, welche die Verbesserung der Wirtschaftlichkeit eines produzierenden Unternehmens durch eine Verbesserung der Produktionssteuerung zum Ziel haben.

ANSORGE (2008) hat ein System zur wandlungsfähigen Auftragsabwicklung in der Produktion unter Verwendung bestehender PPS-Modelle entwickelt. In Abhängigkeit von unterschiedlichen Produktionsbereichen kann eine zentrale oder eine dezentrale PPS realisiert werden. Hierfür werden verschiedene Organisationsstrukturen und Fähigkeiten von Produktionsdienstleistern berücksichtigt. Entscheidend für die Gestaltung des Systems ist der logistische Planungsfreiraum, welcher mit Hilfe von Regeln und Szenarien situationsgerecht bestimmt wird. Anhand einer verhandlungsbasierten Koordinierung erfolgt der Abgleich von Angebot und Nachfrage. Die Realisierung des Systems erfolgt mittels Softwareagenten. Eine situationsbasierte Auswahl von Maßnahmen der Produktionssteuerung basierend auf der aktuellen Produktionssituation erfolgt nicht.

ENGELHARDT (2015) hat ein System für die situationsbasierte Produktionssteuerung im Kontext der auftragsbezogenen Fertigung und Montage unter Verwendung von Radio-Frequency-Identification(RFID)-Daten entwickelt. Das System ist durch die Bestandteile *steuerungsorientierte Produktionsmodularisierung*, *RFID-basiertes hybrides Informationsmanagement* sowie den Einsatz von situationsbasierten Steuerungsverfahren charakterisiert. Mit dem Ziel der Durchlaufzeitreduzierung wird eine synchrone, zweistufige Auftragsfreigabe eingesetzt. Auftretenden Verzögerungen bei der Fertigung von Aufträgen kann durch kurzfristige Kapazitätsanpassungen begegnet werden. Der Einsatz einer intramodularen Schlupfzeitverteilung zur Reihenfolgebildung ermöglicht die zielgerichtete Auftragssequenzierung.

Das Projekt ProSense beschäftigt sich mit der Realisierung einer hochauflösenden, selbstoptimierenden und adaptiven PPS. Grundlage für das System zur Produktionssteuerung ist der Einsatz von intelligenter Sensorik und kybernetischen Unterstützungssystemen. Ausgehend von Rückmeldedaten der Produktion werden automatisch Simulationsmodelle erzeugt. Die Datengranularität wird an den jeweiligen Endanwender angepasst. Die logistischen Zielgrößen werden durch Veränderungen der Stellhebel *maschinelle Kapazität*, *personelle Kapazität*, *Eilauftragslage* und *Auftragsfreigabe* beeinflusst. In Form einer App wird der Produktionsplaner und -steuerer bei den Entscheidungen im Rahmen der PPS simulationsbasiert bestmöglich unterstützt. (SCHUH ET AL. 2015) Durch den Einsatz einer Materialflusssimulationen zur Entscheidungsfindung ist die Menge der Daten, welche innerhalb kürzester Zeit verarbeitet werden kann, limitiert.

NIEHUES (2016) hat ein System zur adaptiven Werkstattsteuerung entwickelt, mit dem Ziel, die Wirtschaftlichkeit unter besonderer Berücksichtigung von Termintreue und Prognostizierbarkeit der Fertigung zu verbessern. Dies erfolgt durch die Optimierung der Auftragsreihenfolge für die Werkstattfertigung. In einem ersten Schritt werden unterschiedliche Störungsklassen erstellt, welche eine zielgerichtete Initiierung von Maßnahmen zur Adaption des Produktionsplans ermöglichen. Die Reaktion auf Störungen erfolgt initial durch den Einsatz von Maßnahmenkaskaden. Ergibt sich hieraus keine Verbesserung des Zielwerts im notwendigen Maß, wird ein evolutionärer Optimierungsalgorithmus eingesetzt. Zur Verbesserung der Rechenzeit des Optimierungsalgorithmus erfolgt eine schrittweise Umplanung des bestehenden Produktionsplans anstelle einer Neuplanung. Im von NIEHUES (2016) entwickelten System werden die Anforderungen von Mitarbeitern allerdings nicht betrachtet. Durch den Einsatz eines evolutionären Optimierungsalgorithmus erfolgt unter dem Gesichtspunkt notwendiger Reaktionszeiten zudem eine Limitierung des durchsuchbaren Lösungsraums.

PIELMEIER (2019) hat ein System zur echtzeitnahen, ereignisbasierten Produktionssteuerung entwickelt. Dieses identifiziert Muster in Ereignisströmen, mit dem Ziel, Entscheidungszeitpunkte für die Produktionssteuerung zu identifizieren. Für die zielgerichtete Produktionssteuerung werden Maßnahmen in einem Maßnahmenportfolio erfasst und anschließend priorisiert und ausgewählt. Das Maßnahmenportfolio enthält Maßnahmen für die Auftragsfreigabe, die Reihenfolgebildung und die Kapazitätssteuerung. Ausgewählt werden die Maßnahmen basierend auf einem Kennzahlensystem, welches auf den logistischen Zielgrößen aufbaut. Es wird ein Optimierungsalgorithmus eingesetzt, welcher einen Branch-and-Bound-

Ansatz mit einem Schrittabenverfahren kombiniert. Zusätzlich wird eine Heuristik eingesetzt, um eine effiziente Anwendung des Optimierungsalgorithmus zu gewährleisten. Zukünftiges Verhalten des Produktionssystems wird im entwickelten System durch die Erweiterung des Optimierungsalgorithmus um einen Look-ahead berücksichtigt (PIELMEIER ET AL. 2018, PIELMEIER ET AL. 2019, PIELMEIER 2019). Durch den Einsatz der Heuristik zur Lösung des Optimierungsproblems ergeben sich einerseits Limitationen hinsichtlich der Lösungsgüte und andererseits steigt mit wachsender Komplexität – repräsentiert durch eine zunehmende Datenmenge – die notwendige Rechenzeit.

WANG ET AL. (2020) beschreiben einen Ansatz, welcher menschliche Entscheidungsfähigkeit und die algorithmenbasierte Umplanung eines Produktionsplans miteinander verknüpft. Ziel ist das Festlegen von optimalen Reihenfolgeregeln (z. B. FIFO). Der Mensch gibt dabei situationsabhängig die zu verbessernden Parameter vor. Ergänzend zu den durch den Menschen bestimmten Parametern werden Eingangsgrößen für das Fuzzy-Modell durch den Einsatz einer Clusteranalyse zur Dimensionsreduktion sowie einer Metaheuristik bestimmt.

WANG ET AL. (2022) haben eine Methode zur Gestaltung einer kollaborativen Entscheidungsfindung entwickelt. Die Methode wählt Regeln für die Auftragsfreigabe der Halbleiterindustrie aus. Durch die Kombination von Mensch und Maschine soll sich die Lösungsgüte der Entscheidungen verbessern. Eine Support Vector Machine trifft initial, basierend auf dem Zustand des Produktionssystems, die Entscheidung über die Verwendung einer Regel zur Auftragsfreigabe aus einer Menge von vordefinierten Auftragsfreigaberegeln. Diese ausgewählte Regel priorisiert die vorhandenen Aufträge und determiniert dadurch die Reihenfolge der Bearbeitung. In Abhängigkeit vom Systemzustand kann eine dynamische Anpassung der Regeln für die Auftragsfreigabe erforderlich sein. Wenn das berechnete Konfidenzlevel zu gering ist, werden die Mitarbeiter in die Entscheidungsfindung miteinbezogen und treffen die finale Entscheidung. Der Lösungsraum der Methode ist allerdings auf die vordefinierten Regeln für die Auftragsfreigabe beschränkt.

Die vorgestellten Ansätze behandeln unterschiedliche Ansätze der Produktionssteuerung im Allgemeinen. Im Abschnitt 2.5.3 werden im Spezifischen Ansätze der Produktionssteuerung untersucht, welche das Paradigma der Agentensysteme nutzen. Dieses bietet insbesondere Vorteile im Hinblick auf die Anpassungsfähigkeit, Skalierbarkeit und Integrationsfähigkeit (VDI/ Verband der Elektrotechnik Elektronik Informationstechnik e.V. [VDE] 2653-1). Zum Schaffen der erforder-

lichen Grundlagen wird im Folgenden zuerst auf die Grundlagen von Agenten sowie Agentensystemen (Abschnitt 2.4) und anschließend auf die Grundlagen von RL (Abschnitt 2.5) eingegangen.

2.4 Agenten und Agentensysteme

2.4.1 Allgemeines

Die zunehmende Komplexität innerhalb der Produktion, induziert durch eine steigende Variantenanzahl bei tendenziell kleiner werdenden Losgrößen sowie höhere Anforderungen an die Reaktionszeit, stellt produzierende Unternehmen vor neue Herausforderungen. Damit der unternehmerische Erfolg langfristig gesichert werden kann, gilt es die Produktion unter Berücksichtigung unternehmensspezifischer Zielgrößen zu optimieren. Das Paradigma der Agentensysteme bietet in diesem komplexen und herausfordernden Umfeld die Möglichkeit, eine hohe Reaktionsfähigkeit bei gleichzeitig hoher Lösungsgüte zu realisieren und unterschiedliche organisatorische Steuerungskonzepte (z. B. dezentrale Steuerungsarchitektur) abzubilden. Zuerst werden in Abschnitt 2.4.2 grundlegende Begrifflichkeiten von Agenten und Agentensystemen näher erläutert. Anschließend erfolgt in Abschnitt 2.4.3 die Charakterisierung von Umgebungen, mit welchen die Agenten interagieren können.

2.4.2 Agenten und Agentensysteme

Eine allgemeingültige Definition von Agenten existiert zum aktuellen Zeitpunkt nicht, allerdings gibt es unterschiedliche Definitionen, von denen einige relevante im Folgenden vorgestellt werden. Ein Agent ist nach VDI/VDE 2653-1 als „*abgrenzbare (Hardware- und/oder Software-) Einheit mit definierten Zielen, die sich auf die Steuerung (gegebenenfalls eines Teils) eines technischen Systems beziehen*“, definiert. WOOLDRIDGE (1999) versteht einen Agenten als Software- oder Hardware-Entität, welche innerhalb einer Umgebung auf Änderungen derselben autonom reagieren kann. RUSSELL & NORVIG (2010) beschreiben einen Agenten als das, was anhand sensorbasierter Wahrnehmungen mittels Aktoren auf eine Umgebung einwirkt. Dementsprechend sind die für die Gestaltung eines Agenten essenziellen Elemente die Umgebung, die Sensoren sowie die Aktoren, welche klar voneinander abgegrenzt werden können (MONOSTORI ET AL. 2006).

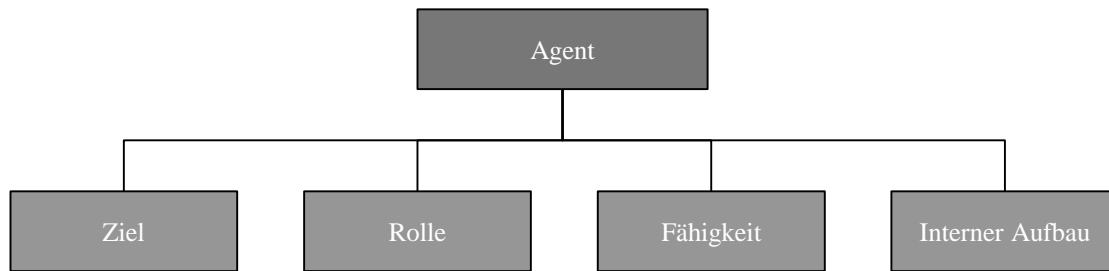


Abbildung 2-8: Charakteristische Eigenschaften eines Agenten

Charakteristisch für ein Agentensystem ist, dass mehrere Agenten zum Lösen einer Aufgabe miteinander interagieren (MONOSTORI ET AL. 2006, VDI/VDE 2653-1). Die Interaktion unterschiedlicher Agenten hat das Ziel der Leistungsmaximierung (CARIDI & CAVALIERI 2004). In Abhängigkeit von der Anwendung können Agenten dabei in ihrer Funktion voneinander differieren (JENNINGS 2001). Prinzipiell können sie in einem Agentensystem entweder kooperativ oder kompetitiv handeln (SUTTON & BARTO 2018). Bei der Kooperation verfolgen Agenten gemeinsam das Ziel, die Leistung des Kollektivs zu verbessern (RUSSELL & NORVIG 2010, SUTTON & BARTO 2018). Handeln sie hingegen kompetitiv, so existieren differierende, ggf. sogar konkurrierende, Ziele (RUSSELL & NORVIG 2010). Unabhängig von der Art der Interaktion kommunizieren die Agenten miteinander. Dies geschieht entweder mittels einer direkten Kommunikation (z. B. mit Hilfe von Kommunikationsprotokollen) oder durch eine indirekte Kommunikation mittels der Umgebung (z. B. über die Auswirkungen der Aktionswahl). (MONOSTORI ET AL. 2006) Ein Agentensystem kann entsprechend der VDI/VDE 2653-2 anhand von *Ziel*, *Rolle*, *Fähigkeit* und *internem Aufbau* charakterisiert werden (siehe Abbildung 2-8).

Das Ziel beschreibt die übergeordnete Intention des Gesamtsystems und wird durch das Agentenverhalten beeinflusst. Aus dem Ziel des Gesamtsystems lassen sich Teilziele für einzelne Agenten ableiten. Die Abgrenzung von Aufgaben bzw. Verantwortlichkeiten erfolgt durch die Rolle der Agenten. Hierdurch kann der Zusammenhang zwischen der Erfüllung der Systemziele und den Agenten systematisch beschrieben werden. Zusätzlich ermöglicht die Definition unterschiedlicher Rollen eine Dekomposition von Aufgaben. Dies hat eine Reduzierung der Komplexität von Aufgaben zur Folge und trägt somit dazu bei, die Komplexität von Lösungsansätzen zu reduzieren. Mit Hilfe der Fähigkeiten werden die technischen Möglichkeiten des Agentensystems zur Erfüllung seiner Aufgaben beschrieben. Der interne Aufbau beschreibt das methodische Vorgehen bei der Modellierung

der Funktionsweise unter Berücksichtigung bspw. der Fähigkeiten oder der Umgebung. (VDI/VDE 2653-2)

2.4.3 Umgebung eines Agentensystems

Die Umgebung der Agenten beschreibt das System, innerhalb welchem die Agenten agieren. In Abbildung 2-9 sind die unterschiedlichen Charakteristika einer Umgebung im Agentenkontext basierend auf RUSSELL & NORVIG (2010) aufgeführt. Hierbei wird ein morphologischer Kasten zu Repräsentationszwecken verwendet. Dabei handelt es sich um eine Kreativitätstechnik, welche ein Problem bzw. eine Fragestellung in die zugrunde liegenden Merkmale zerlegt. Durch die Definition der möglichen Ausprägungen eines jeden Merkmals und die anschließende Kombination derselben können Lösungsalternativen entwickelt werden. (KAUFMANN 2021)

Die Wahrnehmung der Umgebung durch den Agenten beschreibt, wie viele Informationen zu dessen aktuellem Zustand mit Hilfe seiner Sensoren erfasst werden. In einer vollständig beobachtbaren Umgebung nimmt der Agent den Zustand der gesamten Umgebung wahr und kann diesen als Eingangsgröße für die Aktionswahl

Merkmalsausprägung	Merkmal		
Wahrnehmung der Umwelt	Vollständig beobachtbar	Teilweise beobachtbar	Nicht beobachtbar
Auftreten von Ereignissen	Deterministisch		Stochastisch
Aufgabe	Sequenziell		Episodisch
Zeitbezug der Umgebung	Diskret		Kontinuierlich
Modell der Umgebung	Modellfrei		Modellbasiert
Art des Agentensystems	Einzelner Agent		Mehrere Agenten
Verhalten der Umwelt	Statisch	Dynamisch	Semidynamisch

Abbildung 2-9: Beschreibung unterschiedlicher Charakteristika der Umgebung eines Agentensystems mit Hilfe eines morphologischen Kastens

verwenden. Ist die Umgebung nur teilweise beobachtbar, so nimmt der Agent die Umgebung nicht vollständig wahr. Dies kann bspw. durch defekte Sensoren bedingt sein. (RUSSELL & NORVIG 2010)

Ereignisse können entweder deterministisch oder stochastisch auftreten. In einer deterministischen Umgebung tritt bei gleichem Ausgangszustand der Umgebung und gleicher Aktionswahl des Agenten der gleiche Zustand ein. Eine stochastische Umgebung hingegen unterliegt einer Wahrscheinlichkeitsfunktion. Zu einem gewissen Grad können Ereignisse zufällig auftreten. (RUSSELL & NORVIG 2010) Ein Beispiel für wahrscheinlichkeitsbasierte Ereignisse sind Maschinenausfälle in der Produktion.

Mit Blick auf die Aufgaben kann zwischen sequenziellen und episodischen Aufgaben unterschieden werden. Das Ausführen einer Aktion in einer episodischen Umgebung beeinflusst die nächste Episode nicht. In einer sequenziellen Umgebung hat die Wahl einer Aktion einen Einfluss auf zukünftige Entscheidungen. (RUSSELL & NORVIG 2010)

Der Zeitbezug der Umgebung kann in einen diskreten und einen kontinuierlichen Zeitbezug differenziert werden. Eine diskrete Umgebung besteht aus eindeutig voneinander abgegrenzten Ereignissen. Im Gegensatz dazu besteht eine kontinuierliche Umgebung aus ineinander übergehenden Zuständen. (RUSSELL & NORVIG 2010, WASCHNECK 2020)

In einer modellbasierten Umgebung besitzt der Agent Informationen über das Verhalten der Umgebung. Dies bedeutet, dass entweder die Wahrscheinlichkeiten für das Eintreten eines Ereignisses (bei einem stochastischen Auftreten von Ereignissen) oder das eintretende Ereignis selbst (bei einem deterministischen Auftreten von Ereignissen) bekannt ist. Hingegen ist bei einer modellfreien Umgebung das Verhalten der Umgebung nicht bekannt und muss erst erlernt werden. (RUSSELL & NORVIG 2010, SUTTON & BARTO 2018) Agenten besitzen i. d. R. kein vollständiges Modell der Umwelt. Somit ist der Gesamtzustand des Systems dem Agenten nicht vollumfänglich bekannt, beobachtbar und vorhersehbar. (MONOSTORI ET AL. 2006)

Zuletzt kann eine Unterscheidung zwischen einer dynamischen und einer statischen Umgebung getroffen werden. Im Fall einer statischen Umgebung erfolgen ausschließlich Veränderungen der Umgebung, basierend auf Aktionen, welche der Agent wählt. Hingegen verändert sich eine dynamische Umgebung auch ohne das

Eingreifen eines Agenten. Das bedeutet, dass auch Prozesse ablaufen können, welche sich außerhalb des Einflussbereichs des Agenten befinden. Eine halbdynamische Umgebung ist dadurch charakterisiert, dass sich die Umgebung ohne eine Aktion des Agenten nicht verändert, allerdings die Leistung des Agenten einer Änderung unterworfen ist. (RUSSELL & NORVIG 2010)

2.5 Reinforcement Learning

2.5.1 Allgemeines

Bei RL handelt es sich um eine Unterkategorie von ML (GOODFELLOW ET AL. 2016). Der Einsatz von ML bezweckt die Generierung von aufgabenspezifischem Wissen aus Daten, indem von Computern ausgeführte Lernalgorithmen anhand von Beispielen ein komplexes Modell entwickeln (RUSSELL & NORVIG 2010, DÖBEL ET AL. 2018, SCHUH ET AL. 2019). Somit wird es ermöglicht, basierend auf einem definierten Eingabevektor einen problemspezifischen Ausgabevektor zu erhalten (JOSHI 2020).

RL im Speziellen beschreibt das Lernen von Verhaltensmustern durch die Interaktion mit einer Umgebung und das Erzielen von Belohnungen (SUTTON & BARTO 2018). Das formale Framework für RL bildet der Markov-Entscheidungsprozess (MEP). Hierbei handelt es sich um eine mathematisch idealisierte Darstellung des RL-Problems, mit deren Hilfe ein sequenzieller Entscheidungsprozess beschrieben werden kann. Dies erfolgt durch das Quadrupel $(\mathcal{S}, \mathcal{A}, \mathcal{R}, \mathcal{P})$. \mathcal{S} beschreibt den Zustandsraum und repräsentiert damit die Umgebung, innerhalb welcher ein Agent agieren kann. \mathcal{A} bezeichnet eine Menge von Aktionen, aus welchen die auszuführende Aktion gewählt werden kann. \mathcal{P} beschreibt die Übergangswahrscheinlichkeit, dass bei Ausführen einer Aktion a_t im Zustand s_t zum Zeitpunkt $t+1$ der Zustand s_{t+1} erreicht wird. In einem finiten MEP ist der nächste Zustand des betrachteten Systems s_{t+1} ausschließlich von s_t und a_t abhängig. \mathcal{R} entspricht der während der Interaktion erwarteten Belohnung. (SUTTON & BARTO 2018)

Die auszuführende Aktion $a \in \mathcal{A}$ wird entsprechend der Strategie⁵ $\pi(a_t / s_t)$ des Agenten ausgewählt. Grundsätzlich kann die Strategie auf verschiedene Art und Weise, bspw. tabellarisch oder mit einer Wahrscheinlichkeitsfunktion, repräsentiert werden. RL hat das Ziel, die Parameter der Strategie so anzupassen, dass die

⁵ Engl. *policy*

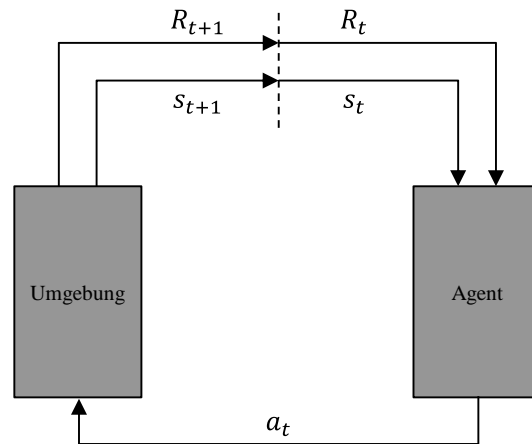


Abbildung 2-10: Interaktion zwischen einem Agenten und seiner Umgebung in einem MEP (SUTTON & BARTO 2018)

erwartete Belohnung maximiert wird. Die Interaktion zwischen einem Agenten und der Umgebung ist in Abbildung 2-10 dargestellt. Basierend auf dem aktuellen Zustand der Umgebung (s_t) wählt der Agent – unter Verwendung der Strategie π – eine Aktion aus. Aus der Aktionswahl resultiert ein neuer Zustand der Umgebung (s_{t+1}). Zusätzlich erhält der Agent die Belohnung R_{t+1} für die Wahl der Aktion a_t (SUTTON & BARTO 2018)

Die erwartete Belohnung des Agenten – basierend auf den Interaktionen des Agenten mit der Umgebung – bis zu einem Zeitpunkt T wird nach

$$R_t = \sum_{k=0}^{T-t-1} \gamma^k r_{t+k+1} \quad (2)$$

mit R_t	erwartete Belohnung zum Zeitschritt t ,
γ^k	Diskontierungsfaktor,
r_{t+k+1}	Belohnung zum Zeitschritt $t+k+1$,
k	Zählvariable für die Zeitschritte nach dem Zeitschritt t und
T	Dauer der Episode

berechnet. Der Diskontierungsfaktor γ , $0 \leq \gamma \leq 1$, dient als Gewichtungsfaktor zur Definition der Bedeutung zukünftiger Belohnungen. Für $\gamma = 1$ werden alle zu erwartenden Belohnungen gleich gewichtet, wohingegen für $\gamma = 0$ einzig die direkte Belohnung zum Zeitpunkt t berücksichtigt wird. (SUTTON & BARTO 2018)

Mit Hilfe einer Wertfunktion kann die erwartete Belohnung für den aktuellen Zustand ausgedrückt werden, wenn der Agent der Strategie π folgt. Die Zustands-Wertfunktion⁶ berechnet sich zu

$$v_{\pi}(s) = \mathbb{E}_{\pi} \left[\sum_{k=0}^{T-t-1} \gamma^k R_{t+k+1} \mid s_t = s \right] \quad (3)$$

mit $v_{\pi}(s)$ Zustands-Wertfunktion der Strategie π im Zustand s ,
 \mathbb{E}_{π} Erwartungswerte der Strategie π und
 s_t aktueller Zustand zum Zeitpunkt t .

Unter Verwendung der Zustands-Wertfunktion ist es möglich, unterschiedliche Zustände hinsichtlich der erwartbaren Belohnung zu bewerten und anschließend den vorteilhaftesten Zustand zu wählen. Die Aktions-Wertfunktion⁷ bewertet die erwartete Belohnung, wenn im aktuellen Zustand s die Aktion a gewählt wird und anschließend die Strategie π verwendet wird. Die Aktions-Wertfunktion kann zu

$$q_{\pi}(s, a) = \mathbb{E}_{\pi} \left[\sum_{k=0}^{T-t-1} \gamma^k R_{t+k+1} \mid s_t = s, a_t = a \right] \quad (4)$$

mit $q_{\pi}(s, a)$ Aktions-Wertfunktion der Strategie π im Zustand s
und für die Aktion a ,
 \mathbb{E}_{π} Erwartungswerte der Strategie π und
 a_t aktuelle Aktion zum Zeitpunkt t

berechnet werden. Ähnlich wie für die Zustands-Wertfunktion ermöglicht die Verwendung der Aktions-Wertfunktion die Auswahl des Zustands-Aktions-Paars, für welches die erwartbare Belohnung den größten Wert annimmt. In der Regel ist die Wertfunktion nicht bekannt und muss approximiert werden. (SUTTON & BARTO 2018)

2.5.2 Deep Reinforcement Learning

Die Herausforderung beim Einsatz von RL ist der Umgang mit einer hohen Dimensionalität von Aktions- und/oder Zustandsräumen. Die Kombination von Deep

⁶ Engl. state-value function

⁷ Engl. action-value function

Learning⁸ und RL – Deep Reinforcement Learning⁹ (DRL) – ermöglicht das Lösen von Problemen mit einer hohen Dimensionalität. Im Rahmen von Deep Learning werden tiefe neuronale Netze¹⁰ verwendet (ARULKUMARAN ET AL. 2017). Um ein Deep Neural Network (DNN) handelt es sich, wenn ein KNN mehrere Schichten zwischen dem Eingabe- und dem Ausgabevektor besitzt (GOODFELLOW ET AL. 2016). Konkret ermöglicht ein DNN die Approximation der Wertfunktionen und/oder der Strategie (siehe Abschnitt 2.5.1).

Für die Umsetzung einer zielgerichteten Produktionssteuerung, welche sich zudem kontinuierlich verbessert, hat sich der Einsatz von DRL für den Lernprozess der Agenten bewährt (PANZER & BENDER 2021). Dies ermöglicht die Realisierung einer Produktionssteuerung, welche trotz einer hohen Dimensionalität des Aktions- und/oder Zustandsraums eine echtzeitnahe Reaktion auf Störungen und gleichzeitig eine hohe Lösungsgüte verspricht (MONOSTORI ET AL. 2016, SUTTON & BARTO 2018).

Prinzipiell können RL-Algorithmen in modellbasierte und modellfreie Verfahren unterschieden werden. Modellbasierte Verfahren nutzen das Modell einer Umgebung zur Problemlösung. Der Agent lernt dabei die Übergangswahrscheinlichkeiten dieser Umgebung (ARULKUMARAN ET AL. 2017, ZHANG & YU 2020). Dies ist bspw. in der Robotik von Vorteil, da dadurch die Menge an notwendigen Interaktionen mit der physischen Welt reduziert werden kann (ARULKUMARAN ET AL. 2017). Allerdings gehen modellbasierte Verfahren mit einem hohen Bedarf nach Rechenleistung für den Lernprozess des Umgebungsmodells einher (FRANÇOIS-LAVET ET AL. 2018, PARK ET AL. 2019). Agenten lernen beim Einsatz eines modellfreien Verfahrens nicht die Übergangswahrscheinlichkeiten, sondern passen ihre Strategie mit Hilfe der Trial-and-Error-Methode an (SUTTON & BARTO 2018, ZHANG & YU 2020). Modellfreie Ansätze sind im Vergleich zu modellbasierten Verfahren weniger komplex und erzielen gleichzeitig bessere Ergebnisse (ARULKUMARAN ET AL. 2017). Im Rahmen dieser Arbeit wird deshalb ein modellfreier Ansatz verwendet. Abbildung 2-11 zeigt die Übersicht über unterschiedliche modellfreie RL-Algorithmen.

⁸ Dt. *tiefes Lernen*

⁹ Dt. *tiefes bestärkendes Lernen*

¹⁰ Engl. *deep neural network (DNN)*

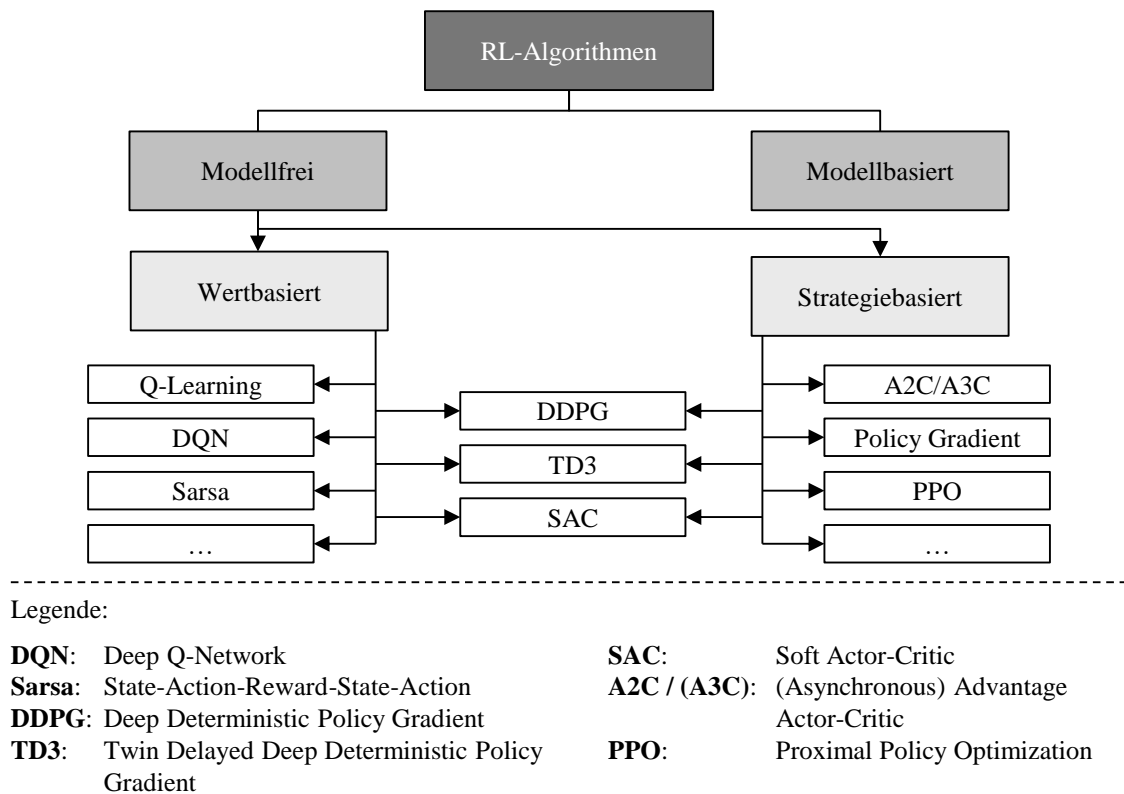


Abbildung 2-11: Einordnung unterschiedlicher RL-Algorithmen in eine Taxonomie für RL (i. A. an ZHANG & YU 2020)

2.5.3 Agentensysteme zur Produktionssteuerung

In den vorherigen Abschnitten (Abschnitt 2.4 und 2.5) wurde das grundlegende Verständnis zu Agentensystemen sowie RL geschaffen. Aufbauend darauf werden in diesem Abschnitt unterschiedliche agentenbasierte Ansätze analysiert. Teilweise wird die Entscheidungsgrundlage mit Hilfe von RL erzeugt, teilweise werden andere Ansätze (z. B. regelbasiert) verwendet.

Mit dem Ziel, die Kennzahlen *Umlaufbestand* und *Auslastung von Maschinen* zu verbessern, haben LEUSIN ET AL. (2018) unterschiedliche Funktionen und Hierarchieebenen (z. B. Produktionssteuerer, Anlagenbediener) innerhalb der Produktion mit unterschiedlichen Typen von Agenten abgebildet. Somit können unterschiedliche Entscheidungsbefugnisse abgebildet und gleichzeitig eine hohe Lösungsgüte erzielt werden. Für die Steuerung der Produktion werden allerdings lediglich Prioritätskennzahlen verwendet.

ALTENMÜLLER ET AL. (2020) nutzen einen agentenbasierten Ansatz zur Kapazitätssteuerung in einer komplexen Werkstattfertigung der Halbleiterindustrie. Der Fokus ihrer Arbeit liegt auf der spezifischen Berücksichtigung von zeitlichen Prozessanforderungen (z. B. maximale Dauer zwischen zwei Prozessschritten). Der für die Kapazitätssteuerung eingesetzte Agent lernt selbstständig. Für den Lernprozess wird der Deep-Q-Network-Algorithmus verwendet. Dieser approximiert die Q-Funktion durch den Einsatz eines KNN. Die Auswahl einer Aktion erfolgt basierend auf den für jede Aktion vorhergesagten Q-Werten. Gewählt wird die Aktion, für welche der höchste Q-Wert prognostiziert wird. Das Update des KNN erfolgt während des Trainings. Zur Verdeutlichung des Potenzials einer agentenbasierten Produktionssteuerung, erfolgt ein Vergleich mit einer Heuristik.

DITTRICH & FOHLMEISTER (2020) beschreiben einen kooperativen Agentenansatz für die Produktionssteuerung. Das System beinhaltet zwei Arten von Agenten. Die Auftragsagenten, welche nach der Freigabe eines Auftrags initialisiert werden, treffen autonom die Entscheidung, an welcher Anlage der Auftrag eingeplant wird. Der Anlagenagent hingegen erfasst und speichert ausschließlich Daten und nimmt somit keinen direkten Einfluss auf das Produktionssystem. Zwischen den Agenten findet ein Informationsaustausch zum aktuellen Systemzustand statt. Dabei geht die Initiierung der Kommunikation stets vom Auftragsagenten aus, welcher eine Entscheidung treffen muss. Somit soll die lokale Optimierung der Produktionssteuerung verhindert werden. Während der Trainingsphase wird der Deep-Q-Network-Algorithmus verwendet.

KIEFER (2020) hat einen Ansatz zur merkmalsbasierten Selbststeuerung entwickelt. Dieser hat das Ziel, eine kontinuierliche Lokalisierung von Objekten durch eine merkmalsbasierte Identifikation sowie eine agentenbasierte Kommunikation zu realisieren. Für die Identifikation wird eine Merkmalshierarchie entworfen, anhand welcher die Einordnung der unterschiedlichen Objekte erfolgt. Für die Kommunikation werden im Rahmen des Ansatzes unterschiedliche Arten von Agenten (z. B. Objektagent, Bereichsagent, Lageragent) eingesetzt. Allerdings besitzen die eingesetzten Agentenarten kein reelles Gegenstück in der Produktion. Das entwickelte Agentensystem bildet die Basis für die dezentrale und autonome Entscheidungsfindung der Agenten. Diese kann entweder regelbasiert (z. B. FIFO) oder situativ stattfinden. Es erfolgt eine Untergliederung der situativen Entscheidungsfindung hinsichtlich der Kooperation der Agenten. Eine weitere, detaillierte Ausgestaltung der situativen Entscheidungsfindung findet nicht statt.

KUHNLE (2020) setzt ein Agentensystem zur Auftragsfreigabe in einer komplexen Werkstattfertigung ein. Hierbei liegt ein Fokus auf der Modellierung des Zustands- und Beobachtungsraums sowie der Belohnungsfunktion für die Produktionssteuerung. Die Strategie der Agenten wird mit Hilfe des Trust-Region-Policy-Optimization-Algorithmus trainiert und verbessert. Im Rahmen seiner Arbeit werden unterschiedliche Belohnungsfunktionen konzipiert (z. B. basierend auf einer mehrkriteriellen Zielfunktion) und anschließend wird das Verhalten der Agenten in Abhängigkeit von diesen Funktionen untersucht. Anhand einer Wafer-Produktion wird das System abschließend evaluiert.

REHBERGER (2020) entwickelt eine Systemarchitektur für ein Steuerungssystem zur Optimierung von Produktionsrouten mit Fokus auf die Wirtschaftlichkeit sowie die Ausfallsicherheit des Produktionssystems. Die hierarchische Systemarchitektur definiert Schnittstellen sowohl zur physischen Umgebung als auch zu IT-Systemen der Produktion. Für das Agentensystem wird ein modularer Ansatz gewählt, welcher aus Ressourcenagenten und einem Produktmanagementagenten besteht. Entscheidungen über die bestmögliche Produktionsroute werden durch zwei unterschiedliche Wissensbasen getroffen. Hierfür kann einerseits ein Simulationsmodell und andererseits ein gerichteter, gewichteter Graph eingesetzt werden.

WASCHNECK (2020) hat in seiner Forschungsarbeit ein System zur autonomen Entscheidungsfindung in einer komplexen Werkstattfertigung im Rahmen der Produktionssteuerung am Anwendungsbeispiel der Halbleiterindustrie entwickelt. Für die autonome Entscheidungsfindung verwendet er ein Agentensystem in Kombination mit DRL. Konkret handelt es sich beim DRL-Algorithmus um Deep-Q-Learning. WASCHNECK ET AL. (2018) gestalten den Trainingsprozess zweistufig. In der ersten Phase wird ausschließlich ein Agent trainiert, die restlichen Agenten werden von Heuristiken gesteuert. Anschließend, in der zweiten Phase, werden die vortrainierten Agenten gemeinsam trainiert. Mit Hilfe des Agentensystems erfolgt die Auftragsfreigabe von Produktionsaufträgen einer Wafer-Produktion. Der Fokus der Arbeit liegt auf der Verbesserung der Liefertermintreue von Aufträgen. Resultierende Rüstzeiten und die damit verbundenen, potenziell negativen Auswirkungen auf andere Aufträge werden nicht berücksichtigt. Weiterhin setzt WASCHNECK (2020) keine Erklärbarkeitsansätze von KNN zur Steigerung der Nachvollziehbarkeit um.

MAY ET AL. (2021) untersuchen den Einsatz eines Agentensystems zur Steuerung einer Matrixproduktion. Es werden drei Arten von Agenten konzipiert. Diese repräsentieren Bauteile, Anlagen und fahrerlose Transportfahrzeuge. Sowohl Heuristiken als auch KNN können für die Aktionswahl eingesetzt werden. Die Aktionen bestehen aus der Auswahl von Geboten, welche in einem kostenbasierten Gebotssystem erfasst werden. Im Rahmen einer Simulationsstudie wird die Performanz der Agenten anhand zweier Größen – Auslastung und Durchlaufzeit – quantifiziert.

RÖSCH (2021) hat ein System zur energieoptimierten Produktionssteuerung, basierend auf einem Agentenansatz mit DRL, entwickelt. Ressourcenagenten sowie jeweils ein Speicher- und ein Marktagent bilden die Grundlage für die dezentrale Systemarchitektur. Das Training der Agenten erfolgt unter Verwendung des Algorithmus Proximal Policy Optimization (PPO) als Actor-Critic-Ansatz. Die Belohnungsfunktion ist aus dem entwickelten gesamtkostenbasierten Zielsystem für die Produktionssteuerung abgeleitet und hat globale und lokale Anteile. Der lokale Anteil der Belohnung beinhaltet ausschließlich die Produktionskosten. In der globalen Belohnung sind ausschließlich die Energiekosten enthalten. Eine lokale Belohnung wird somit ausschließlich an Ressourcenagenten vergeben, wohingegen die globale Belohnung ausschließlich an den Handelsagenten und den Speicheragenten vergeben wird. Weiterhin werden sich stark unterscheidende Rüstzeiten im Rahmen der Arbeit nicht berücksichtigt. Die Zuweisung vorhandener Aufträge zu Anlagen wird als gegeben angenommen und nicht durch das entwickelte System gesteuert.

BAUER (2022) hat ein System zur Optimierung der Produktionssteuerung für die komplexe Werkstattfertigung entwickelt. Ein Regelkreis beschreibt die Interaktion zwischen der Produktionssteuerung und der Produktion. Dieser wird um aus dem Wertschöpfungsnetzwerk stammende Ereignisse erweitert, welche relevant für die Produktionssteuerung sind. Maßnahmen, welche im Kontext der Produktionssteuerung ausgelöst werden, beschränken sich im Rahmen der Arbeit auf die Anpassung der Priorisierung von Fertigungslosen, welche sich bereits im Produktionssystem befinden. Die konkrete Auswahl einer Anlage erfolgt weiterhin durch eine bestehende Freigabelogik. BAUER (2022) setzt auf einen einzelnen Agenten, welcher die Priorisierung der Aufträge für eine Maschinengruppe vornimmt.

Alle analysierten Ansätze haben gezeigt, dass es unterschiedliche Ansätze für die Realisierung einer agentenbasierten Produktionssteuerung gibt. Allerdings wird dabei der Benutzer der Systeme nicht berücksichtigt. Bei den meisten Ansätzen

handelt es sich um autonome Systeme zur Produktionssteuerung. Diese haben gemein, dass im Entscheidungsprozess die Mitarbeiter bzw. deren Entscheidungsfreiräume nur geringfügig einbezogen werden. Die Verbesserung der Nachvollziehbarkeit sowie die Akzeptanz der Mitarbeiter gegenüber systemischen Entscheidungen gilt es näher zu betrachten. Einflussfaktoren auf den menschlichen Entscheidungsprozess wie Systeme zur Entscheidungsunterstützung werden deshalb im Abschnitt 2.7 untersucht.

2.6 Ansätze zur Erklärbarkeit

2.6.1 Allgemeines

Im Kontext von ML-Verfahren bzw. Ansätzen der Künstlichen Intelligenz (KI) wird die bereits bestehende Problematik des mangelnden Vertrauens in Entscheidungsvorschläge von Systemen weiter verschärft. Beim Einsatz von ML-Verfahren respektive DRL-Verfahren kommen häufig sogenannte Blackbox-Modelle – auch als opake Modelle¹¹ bezeichnet – wie bspw. KNN zum Einsatz, bei welchen die Lösungsfindung ohne zusätzliche Schritte nicht erklärbar ist (DÖBEL ET AL. 2018).

Im Folgenden wird zuerst die Erklärbarkeit im Kontext von ML-Verfahren definiert. Anschließend werden verschiedene Ansätze für eine erklärbare Entscheidungsfindung identifiziert und charakterisiert (Abschnitt 2.6.2). Abschließend erfolgt die Vorstellung unterschiedlicher Ansätze, um die Erklärbarkeit von ML-Modellen zu realisieren (Abschnitt 2.6.3).

2.6.2 Erklärbarkeit im Kontext von Maschinellem Lernen

In der Literatur existieren für den Begriff der Erklärbarkeit im Kontext von ML-Verfahren unterschiedliche Definitionen. MURDOCH ET AL. (2019) definieren Erklärbarkeit als Extraktion von gelernten Beziehungen eines trainierten Modells. Diese Beziehungen können entweder in den Daten des Produktionssystems vorhanden sein oder durch Interaktionen mit ebendiesem oder bspw. einem Simulationsmodell erlernt werden. Demgegenüber definieren GUIDOTTI ET AL. (2019) Er-

¹¹ Bei einem opaken Modell ist der Zusammenhang zwischen dem Eingabe- und dem Ausgabevektor nicht direkt ersichtlich. Es können somit (fast) keine Rückschlüsse auf die innere Funktionsweise des Modells gezogen werden (ZEDNIK 2021).

klärungen als eine Schnittstelle zwischen den Benutzern und einem System, welches sowohl dem Benutzer die Entscheidungen verständlich darlegt als auch als ein genauer Stellvertreter des Systems fungiert. MONTAVON ET AL. (2018) definieren in ihrer Arbeit Erklärbarkeit als den Beitrag unterschiedlicher Merkmale¹², welche für einen bestimmten Gültigkeitsbereich zu einer Entscheidung beigetragen haben. GILPIN ET AL. (2018) beschreiben Erklärbarkeit im Kontext von ML mit Hilfe von Anforderungen, welche erfüllt sein müssen. Diese sind das Zurverfügungstellen der Einflussfaktoren auf das Verhalten von KNN, das Erlangen des Vertrauens von Nutzern oder die Erzeugung von Erkenntnissen bzgl. der Einflussfaktoren für eine Entscheidung. BARREDO ARRIETA ET AL. (2020) charakterisieren Erklärbarkeit als das Darlegen von Einflussfaktoren auf die Entscheidung eines Modells, um dessen Funktionsweise unter Berücksichtigung eines Zielpublikums klar oder leicht verständlich zu veranschaulichen. Im Rahmen dieser Arbeit wird die Erklärbarkeit entsprechend der Definition von BARREDO ARRIETA ET AL. (2020) verstanden, da diese Definition einerseits eine Offenheit für die Art und Weise der Realisierung der Erklärbarkeit ermöglicht und andererseits die Bedeutung der Adressaten klar hervorhebt.

Die Nachvollziehbarkeit bzw. die Verständlichkeit eines Modells kann durch Verfahren der Erklärbarkeit erzeugt werden (BURKART 2022). Die Erklärbarkeit von Modellen im Kontext von ML-Verfahren kann prinzipiell durch zwei Ansätze realisiert werden (siehe Abbildung 2-12). Einerseits können *Ante-hoc-Verfahren* und andererseits *Post-hoc-Verfahren* eingesetzt werden.

Ante-hoc-Verfahren sind dadurch charakterisiert, dass die Entscheidungen, welche von den eingesetzten Modellen – auch als transparente Modelle bezeichnet – getroffen werden, direkt nachvollzogen werden können. Ein Beispiel für ein solches transparentes Modell ist ein Entscheidungsbaum. Beim Einsatz eines Entscheidungsbaums kann das Entscheidungskriterium direkt an jedem Knoten abgelesen werden. Somit ist es prinzipiell möglich, den Entscheidungsprozess vollständig nachzuvollziehen und einen hohen Grad an Erklärbarkeit zu realisieren. (BARREDO ARRIETA ET AL. 2020) Allerdings kann es für diese Art der Erklärbarkeit erforderlich sein, mathematische Grundkenntnisse zu besitzen (LANGER ET AL. 2021). Der Kreis der Adressaten, welcher von der Erklärbarkeit systemischer Entscheidungsvorschläge profitiert, ist somit eingeschränkt oder es sind vorab Schulungen notwendig. Zusätzlich ist die Vorhersagegenauigkeit der Algorithmen, welche zu den

¹² Ein Merkmal (engl. *feature*) beschreibt eine messbare Eigenschaft einer Beobachtung (WITTEN ET AL. 2011).

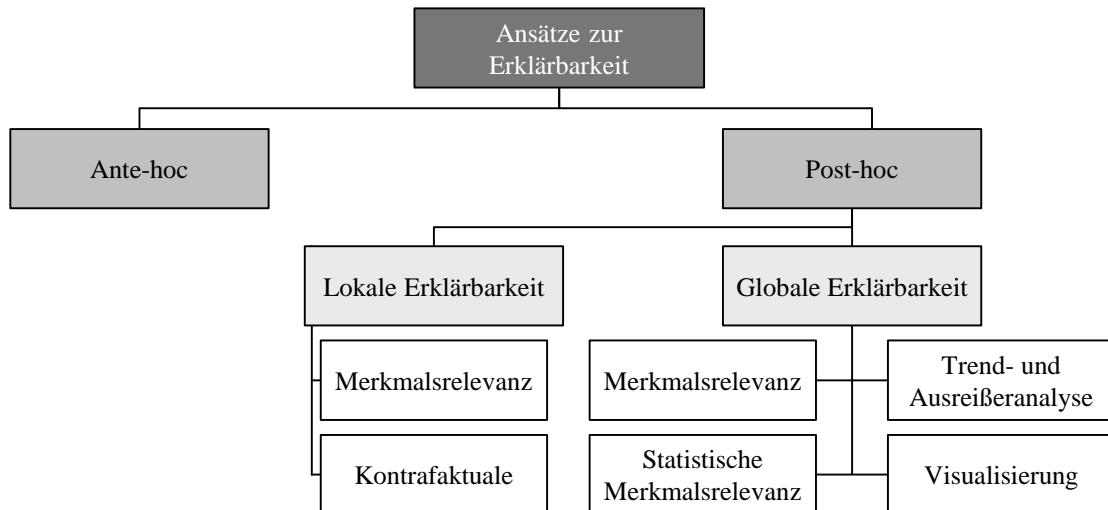
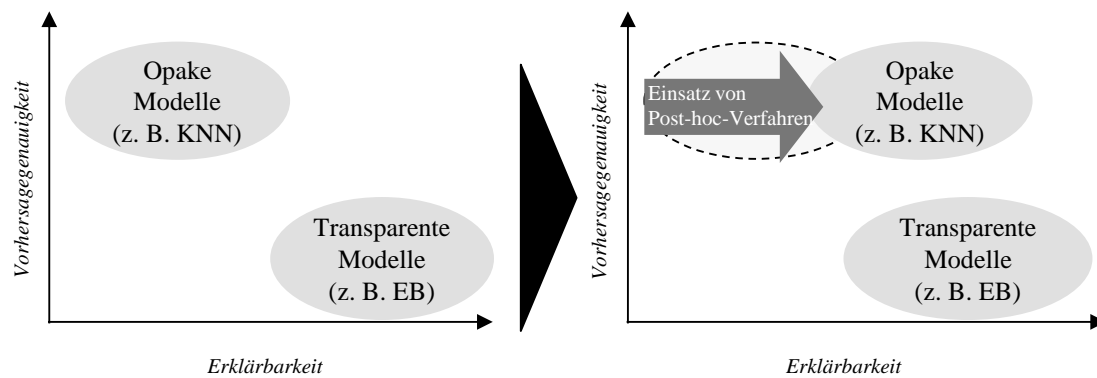


Abbildung 2-12: Kategorisierung der Ansätze von erklärbaren KI (i. A. an MURDOCH ET AL. 2019)

Ante-hoc-Verfahren zählen, tendenziell niedriger als die der Post-hoc-Verfahren (siehe Abbildung 2-13).

Der Einsatz von Post-hoc-Verfahren bedeutet, dass ein Modell (z. B. KNN) unabhängig von den Aspekten der Erklärbarkeit trainiert wird. Somit gilt, dass das zugrunde liegende Modell nicht verändert wird. Hierdurch werden die Vorteile komplexer Modelle hinsichtlich der Performanz genutzt und es können komplexe Entscheidungssituationen gelöst werden. Damit trotzdem eine Erklärbarkeit des Modells erzielt werden kann, wird ausgehend vom trainierten Modell ein Stellvertretermodell – auch Surrogatmodell genannt – erzeugt, welches das Bereitstellen von Erklärungen ermöglicht (HENELIUS ET AL. 2014, BURKART 2022). Die Erklärung des Modells kann entweder für einzelne Vorhersagen (lokale Erklärbarkeit) oder für die allgemeinen gelernten Beziehungen des Modells (globale Erklärbarkeit) erfolgen (ADADI & BERRADA 2018, MURDOCH ET AL. 2019). In Abbildung 2-13 wird qualitativ gezeigt, dass mit Hilfe von Post-hoc-Verfahren die Erklärbarkeit von opaken Modellen bei gleichbleibender Genauigkeit erhöht werden kann. Allerdings ist wie bei Ante-hoc-Verfahren auch bei den Post-hoc-Verfahren nicht gewährleistet, dass alle Adressaten die Erklärungen ohne entsprechende Vorkenntnisse nachvollziehen können (LANGER ET AL. 2021).

Damit die Endanwender der Systeme den größtmöglichen Nutzen aus den Systemen bzw. deren Handlungsempfehlungen ziehen können, gilt es deren Anforderungen bei der Entwicklung des Systems gezielt zu berücksichtigen.



Legende:

KNN: Künstliches neuronales Netz

EB: Entscheidungsbaum

Abbildung 2-13: Qualitativer Vergleich von opaken und transparenten Modellen. Veranschaulichung des Einflusses von Post-hoc-Verfahren auf die Erklärbarkeit von opaken Modellen. (i. A. an ADADI & BERRADA 2018)

2.6.3 Ansätze zur Erklärbarkeit von systemischen Entscheidungen im Produktionsumfeld

REHSE ET AL. (2019) nutzen Ansätze des erklärbaren ML im Rahmen einer Modellfabrik. Hierbei werden mit Hilfe eines rekurrenten neuronalen Netzes Vorhersagen über den weiteren Verlauf der Produktionsprozesse getroffen. Eine Integration des Nutzers erfolgt über die Eingabe eines Grenzwerts, in Abhängigkeit dessen die Vorhersagegüte des Modells berechnet wird. Die Einflussfaktoren auf diese Vorhersagen werden anschließend mit Hilfe von Local Interpretable Model-Agnostic Explanations (LIME) – einer Post-hoc-Methode – bestimmt. Hierbei wird sowohl eine lokale als auch eine globale Erklärbarkeit realisiert und dem Nutzer anschließend visualisiert. Bei der lokalen Erklärung von Entscheidungen erfolgt sowohl eine Visualisierung der Merkmalsrelevanz als auch eine Ableitung spezifischer Entscheidungsregeln. Beide Arten der Erklärung werden zusätzlich textuell beschrieben.

Die Identifikation von kausalen Beziehungen zur Erklärung der Entscheidungen eines DRL-basierten Systems wurde von MADUMAL ET AL. (2020) untersucht. Das kausale Modell wird hier basierend auf den Trainingsdaten der Agenten unter Verwendung eines multivariaten Regressionsmodells trainiert. Mit Hilfe des kausalen

Modells können anschließend Kontrafaktuale erzeugt werden. Die Validierung erfolgt anhand unterschiedlicher Benchmark-Anwendungsfälle. Bei diesem Ansatz kommen ausschließlich kategorische Variablen zum Einsatz. Weiterhin wird der Beobachtungsraum vorab manuell stark eingeschränkt.

Ein Ansatz für die lokale und globale Erklärbarkeit des Verhaltens eines einzelnen DRL-Agenten entwickelten HUBER ET AL. (2021). Mit Hilfe einer Salienzkarte werden die Datenpunkte aufgezeigt, welche den größten Einfluss auf eine einzelne Entscheidung des Agenten haben. Die allgemeine Strategie der Agenten – und damit die globale Erklärbarkeit – wird anhand einer Zusammenfassung des Verhaltens des Agenten in unterschiedlichen Entscheidungssituationen, basierend auf einer Weiterentwicklung des Algorithmus HIGHLIGHTS (AMIR & AMIR 2018), verdeutlicht. Ziel ist es, die Auswirkung einer divergierenden Aktionswahl auf das Produktionssystem zu bestimmen. Anhand einer simulationsbasierten Evaluation einer begrenzten Abfolge von Aktions-Zustands-Paaren werden diese repräsentativen Beispiele ausgewählt.

KUHNLE ET AL. (2021) untersuchen die Entscheidungslogik eines einzelnen Agenten, dessen Strategie durch DRL bestimmt wird, mit Hilfe eines Entscheidungsbaumes sowie einer Salienzkarte. Der Entscheidungsbaum, ein Vertreter der modellbasierten Erklärbarkeit, wird mit Hilfe von erfassten Trainingsdaten erstellt. Diese bestehen aus dem Zustand des Produktionssystems¹³ sowie der zugehörigen Aktion des Agenten. Als Ergebnis kann somit die Entscheidungslogik des Agenten identifiziert werden. Allerdings nimmt bei einer größeren Anzahl von Beobachtungen sowie möglichen Aktionen die Tiefe des Entscheidungsbaums tendenziell zu und somit die Nutzbarkeit der Entscheidungslogik ab. Demnach gelingt die umfassende Erklärbarkeit der Entscheidungen des Agenten nicht (KUHNLE ET AL. 2021). Auf der Salienzkarte werden die Merkmale hinsichtlich ihres Einflusses auf eine einzelne Entscheidung des Agenten kategorisiert. Der Einfluss wird direkt aus dem KNN des Agenten abgeleitet. (KUHNLE ET AL. 2021)

LANGER ET AL. (2021) identifizieren in einem ersten Schritt mehrere Hauptstakeholder eines KI-basierten Systems. Diese sind *Entwickler, Nutzer, Anbieter, Auditoren* und *durch das System beeinflusste Personen*. Identifizierte Desiderate werden anschließend den Stakeholdern zugeordnet und für die Entwicklung eines Konzepts des KI-basierten Systems verwendet. Hierbei wird hervorgehoben, dass insbesondere bei der Entwicklung eines erklärbaren KI-basierten Systems Er-

¹³ Engl. *observation space*

kenntnisse aus unterschiedlichen Disziplinen (z. B. Domänenexpertise, Informatik, Psychologie) berücksichtigt werden müssen. LANGER ET AL. (2021) empfehlen eine Kombination unterschiedlicher Explainable-Artificial-Intelligence-Techniken, um die Anforderungen unterschiedlicher Stakeholder zu erfüllen. Die Anwendung ihres Konzepts beschreiben sie ausschließlich anhand eines hypothetischen Beispiels, in dem ein System entwickelt werden soll, welches eine faire Entscheidungsfindung realisiert.

2.7 Entscheidungstheorie und Entscheidungsunterstützungssysteme

2.7.1 Allgemeines

Durch die wachsende Menge an erfassten Daten und Informationen im Produktionsumfeld steigt gleichzeitig die Datenmenge, welche es bei der Entscheidungsfindung zu berücksichtigen gilt. Einerseits ermöglicht dies, die Entscheidungsqualität zu verbessern. Andererseits wird dadurch die Entscheidungsfindung komplexer. (RASHEDI 2022) Insbesondere in der Produktionssteuerung ist das zuverlässige und schnelle Treffen von Entscheidungen unter Berücksichtigung unterschiedlicher Randbedingungen von essenzieller Bedeutung. Die Qualität und die Reaktionsfähigkeit haben einen direkten Einfluss auf den wirtschaftlichen Erfolg eines Unternehmens (STEINLEIN ET AL. 2020). Aufgrund der zunehmenden Komplexität bei gleichzeitig steigendem Zeitdruck bedarf es eines Systems, welches den Menschen bei seinen Entscheidungen unterstützt (KASIE ET AL. 2017). Die durch den Menschen getroffenen Entscheidungen hängen von unterschiedlichen Einflüssen ab. Diese sowie das resultierende Entscheidungsverhalten werden durch die Entscheidungstheorie beschrieben.

Eine Entscheidung im Sinne der Entscheidungstheorie beschreibt stets die Auswahl aus mehreren Handlungsalternativen (LAUX ET AL. 2018). Ein Entscheidungsproblem ist durch die Frage charakterisiert, welche Handlungsalternative gewählt werden soll. Damit tatsächlich eine Entscheidung vorliegt, muss die Auswahl einer Handlungsalternative einen besseren Grad der Zielerreichung zur Folge haben. (LAUX & LIERMANN 2005, LAUX ET AL. 2018)

Entsprechend dem Ziel der Entscheidungstheorie erfolgt eine Unterscheidung in deskriptive und präskriptive (normative) Entscheidungstheorien. Die deskriptive Entscheidungstheorie beschreibt anhand der Realität das Entscheidungsverhalten

von Personen. Ausgehend vom tatsächlichen Entscheidungsverhalten von Personen werden empirische Hypothesen erstellt, mit Hilfe derer anschließend Entscheidungen prognostiziert werden können. (LAUX & LIERMANN 2005, LAUX ET AL. 2018)

Die präskriptive Entscheidungstheorie hingegen zielt darauf ab, Regeln für das rationale Treffen von Entscheidungen zu erstellen. Im Gegensatz zur deskriptiven Entscheidungstheorie wird nicht das tatsächliche Entscheidungsverhalten von Personen abgebildet, sondern das Entscheidungsverhalten wird ausgehend von konkreten Entscheidungssituationen abstrahiert. Dadurch soll dem Entscheider in verschiedenen Entscheidungssituationen, in welchen unterschiedliche Zielgrößen im Konflikt zueinander stehen sowie eine ungewisse Zukunft herrscht, eine Hilfestellung gegeben werden. (LAUX & LIERMANN 2005, LAUX ET AL. 2018)

2.7.2 Entscheidungsmodell

Ein Entscheidungsmodell überführt die relevanten Elemente und Beziehungen einer Entscheidungssituation in eine formalisierte Sprache. Daraus kann die Entscheidung logisch deduziert werden. (BRETZKE 1980) Jedes Entscheidungsmodell kann mittels eines *Entscheidungsfelds* und einer *Entscheidungsregel* charakterisiert werden (siehe Abbildung 2-14). Das Entscheidungsfeld wiederum besteht aus den Bausteinen *Handlungsalternativen*, *Umweltzustände* und *Ergebnisse*. Handlungsalternativen beschreiben eine Menge von mindestens zwei Alternativen (A_{alt}), zwischen denen der Entscheider wählen und die er selbst beeinflussen kann. Umweltzustände (S_{Umwelt}) sind nicht direkt durch den Entscheider beeinflussbar (z. B. Nachfragemenge der Kunden), beeinflussen allerdings die Ergebnisse der Handlungsalternativen. Das Wahrscheinlichkeitsurteil eines Entscheiders über das Eintreten der Umweltzustände ($w(S_{Umwelt})$) wird durch dessen Informationsstruktur und Prognosefunktion – die wahrscheinlichkeitsbasierten Rückschlüsse – determiniert. Die Ergebnisse (E_{as}) sind die Beurteilung der verfügbaren Alternativen anhand der für den Entscheider relevanten Zielgrößen. Hierbei kann es sich sowohl um eine einzige Zielgröße (z. B. Gewinn) als auch um mehrere Zielgrößen (z. B. Gewinn und Umsatz) handeln. Mit Hilfe der Entscheidungsregel kann eine rationale Entscheidung aus Handlungsalternativen gewählt werden. Die Bewertung von Alternativen erfolgt mittels eines Präferenzwerts, welcher durch die Präferenzfunktion $\phi(A_{alt})$ berechnet wird. Somit definiert die Entscheidungsregel idealisiert die Art und Weise, wie aus einer Menge an Handlungsalternativen eine Entscheidung für eine Handlungsalternative ($A_{\hat{alt}}$) getroffen wird. (LAUX & LIERMANN 2005, LAUX ET AL. 2018)

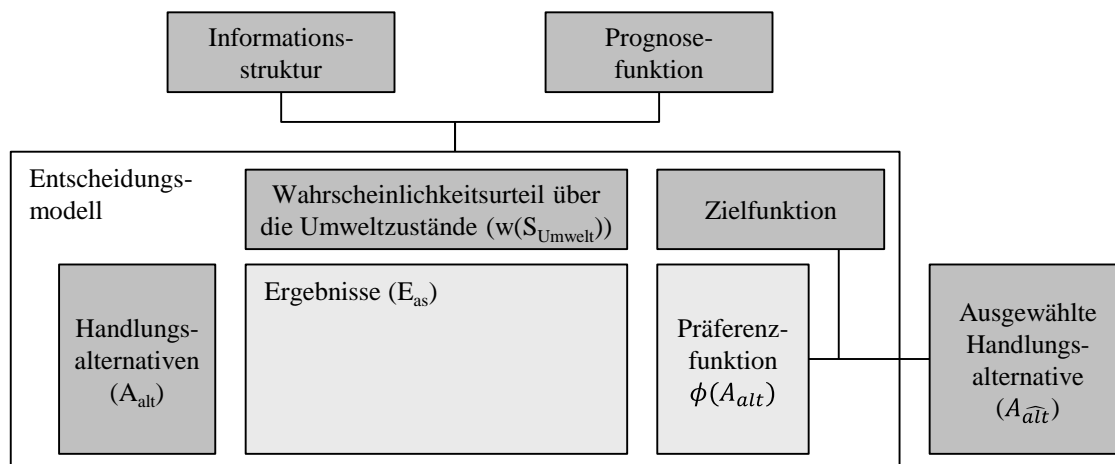


Abbildung 2-14: Veranschaulichung der Primärdeterminanten der Entscheidung (i. A. an LAUX & LIERMANN 2005)

Generell besteht eine Limitierung des Menschen hinsichtlich der Aufnahme, des Speicherns und der konsistenten Verarbeitung von Daten. Zusätzlich kann der manuelle Aufwand für das Erstellen einer Ergebnismatrix sehr hoch sein. Diesen Herausforderungen kann durch den Einsatz von Informationssystemen zur Unterstützung der Entscheidungsfindung begegnet werden. (LAUX & LIERMANN 2005)

Im Zuge der fortschreitenden Digitalisierung werden Entscheider bei der Auswahl von Handlungsalternativen immer häufiger durch Informationssysteme unterstützt. Die Bestandteile des Entscheidungsmodells werden hierbei teilweise oder vollständig durch das Informationssystem (sog. Entscheidungsunterstützungssystem) abgebildet. Zentraler Aspekt hierbei ist die Interaktion zwischen dem Entscheider und dem Informationssystem. Deren Häufigkeit nimmt stetig zu (WASCHULL ET AL. 2020). Interaktionen können dabei das Suchen nach bzw. das Anzeigen von Informationen sowie das Vorbereiten von Entscheidungen beinhalten.

2.7.3 Ansätze zur Entscheidungsunterstützung

Trotz fortschreitender Digitalisierung und Automatisierung von Herstellungsprozessen spielt der Mensch – indirekt als Entscheider oder direkt als ausführender Mitarbeiter – weiterhin eine zentrale Rolle in der Produktion (MÜLLER & RIEDEL 2014, WENZEL ET AL. 2017). Das Treffen der korrekten Entscheidungen durch Mitarbeiter erfordert hochwertige, gefilterte Informationen als Entscheidungs-

grundlage (KLETTI & DEISENROTH 2021). Damit die Daten entsprechend aufbereitet und verdichtet werden können, um Mitarbeiter in ihrer Rolle als Entscheider zielgerichtet mit Informationen unterstützen zu können, lassen sich Systeme zur Entscheidungsunterstützung einsetzen (KLETTI & DEISENROTH 2021). Durch den unterstützenden Charakter solcher Systeme wird die Integration des Expertenwissens des Entscheiders in den Entscheidungsprozess ermöglicht.

Ziel der Systeme zur Entscheidungsunterstützung im Kontext der PPS ist es, Entscheidungen in komplexen Entscheidungssituationen vorzubereiten (SCHUH ET AL. 2014). Bei der Auswahl der Handlungsalternative soll der Entscheider explizit berücksichtigt werden und die finale Entscheidung treffen. Somit kann eine Synthese zwischen den Fähigkeiten des technischen Systems und den Fähigkeiten des Menschen entstehen (HINRICHSSEN & BORNEWASSER 2019). Dadurch wird der möglichst vorteilhafte Einsatz von menschlichen und technischen Ressourcen zur Hebung von sowohl ökonomischen als auch technologischen Potenzialen von Automatisierungslösungen ermöglicht (GROTE 2005, HIRSCH-KREINSEN 2015). Die vollständige Automatisierung des Entscheidungsprozesses ist somit nicht das Ziel von Entscheidungsunterstützungssystemen.

NUNES & JANNACH (2017) weisen, basierend auf der Analyse von Nutzerstudien, darauf hin, dass für die erfolgreiche Umsetzung von Entscheidungsunterstützungssystemen in Unternehmen sowohl die Korrektheit der Entscheidungsvorschläge als auch die Nachvollziehbarkeit der Handlungen des Systems als essenziell zu betrachten sind. Damit ein System entwickelt werden kann, welches die Anforderungen an Lösungsgüte und Akzeptanz bei den Anwendern erfüllt, gilt es bereits im Entwicklungsprozess die Erfordernisse der Nutzer zu berücksichtigen (COHN 2004). POWER (2002) weist zusätzlich darauf hin, dass bei der Realisierung eines Systems zur Entscheidungsunterstützung die Möglichkeit für eine adaptive Anpassung entsprechend den Fähigkeiten der Benutzer vorzusehen ist. Somit kann eine hohe Nutzerzentrierung des Systems erzielt werden.

Abbildung 2-15 zeigt eine Klassifikation von Entscheidungsunterstützungssystemen basierend auf POWER (2004). Die primäre Klassifikation der Entscheidungsunterstützungssysteme erfolgt in *datengetrieben*, *modell-*, *wissens-*, *dokumenten-* und *kommunikationsbasiert*. Sekundär können sich die Entscheidungsunterstützungssysteme hinsichtlich der *Adressaten*, des *Zwecks* und der *Art der Realisierung* unterscheiden.

Datengetriebene Entscheidungsunterstützungssysteme sind charakterisiert durch einen Zugang zu strukturierten Datenbanken mit quantitativen Daten. In den Datenbanken kann eine große Menge an Daten abgespeichert sein. Vertreter, welche dieser Kategorie zugeordnet werden können, sind u. a. Data-Mining-Ansätze oder Online Analytical Processing. Die Visualisierung der Daten bzw. der Datenanalyse erfolgt über Dashboards. (POWER 2002, 2004, MÜLLER & LENZ 2013)

Modellbasierte Ansätze benötigen im Gegensatz zu den datengetriebenen Ansätzen keine großen Datenmengen. Die Funktionalität wird durch die Verwendung von mathematischen Ansätzen generiert. Vertreter dieser Kategorie sind z. B. Gleichungs-, Ungleichungs- oder Fuzzy-Systeme. Optimierungs-, Simulations- und Prognosesysteme zählen ebenfalls zur Kategorie der modellbasierten Ansätze. (POWER 2002, 2004, MÜLLER & LENZ 2013) Simulationsbasierte Ansätze zur Evaluation von Handlungsalternativen im Rahmen der PPS sind mit einem hohen Aufwand verbunden. Dies ist in der notwendigen Anzahl von Iterationen und der daraus resultierenden hohen Laufzeit von simulationsbasierten Ansätzen begründet. (PIELMEIER 2019)

Die dokumentenbasierten Ansätze haben das Ziel, Mitarbeiter bei der Beherrschung bzw. beim Durchsuchen von unstrukturierten Daten (z. B. Textdateien,

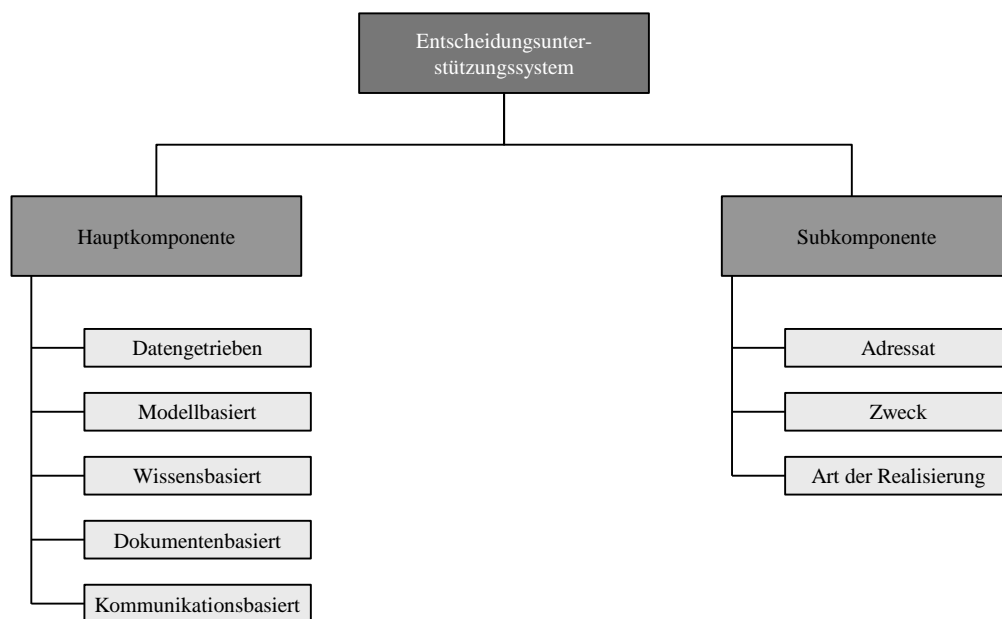


Abbildung 2-15: Klassifikation von Entscheidungsunterstützungssystemen (i. A. an POWER 2002, 2004)

Präsentationsdateien) zu unterstützen. Werkzeuge wie bspw. Text und Web-Mining können für die Detektion von Mustern in den Daten verwendet werden. (POWER 2002, MÜLLER & LENZ 2013, PIELMEIER 2019)

Zu den kommunikationsbasierten Ansätzen werden Systeme gezählt, welche die Kommunikation zwischen und Kollaboration von Entscheidungsträgern ermöglichen bzw. erleichtern (POWER 2002, 2004). Programme für das Durchführen von Videokonferenzen sowie interaktiven Workshops sind Vertreter dieses Ansatzes (MÜLLER & LENZ 2013).

Wissensbasierte Systeme empfehlen dem Entscheider konkrete Handlungen (POWER 2002). Zur Erzeugung von Handlungsempfehlungen werden unterschiedliche Methoden aus verschiedenen Gebieten – ML, Expertensysteme, Data-Mining und Kommunikationstechnologien – miteinander verknüpft (BEIERLE & KERN-ISBERNER 2019, PIELMEIER 2019). Wissensbasierte Systeme zeichnen sich durch die Fähigkeit der Problemlösung aus. Basierend auf vorhandenen Daten und dem daraus gewonnenen Wissen können logisch neue Schlussfolgerungen gezogen werden. (MÜLLER & LENZ 2013) Im Rahmen der vorliegenden Arbeit liegt der Fokus auf den daten-, modell- und wissensbasierten Ansätzen für ein System zur Entscheidungsunterstützung.

NELLES ET AL. (2016) haben im Rahmen des Projekts ProSense (hochauflösende Produktionssteuerung auf Basis kybernetischer Unterstützungssysteme und intelligenter Sensorik) ein modellbasiertes System zur Entscheidungsunterstützung vorgestellt. Unterschiedliche Handlungsalternativen werden hier simulationsbasiert bewertet und anschließend den Nutzern zur Verfügung gestellt. Die Interaktion zwischen den Nutzern und dem Entscheidungsunterstützungssystem erfolgt tabletbasiert mittels einer graphischen Nutzerschnittstelle. Vier Übersichtsebenen – Produktionsbereich, Maschine, Aufträge und Wochenübersicht – stehen den Nutzern für Detailanalysen zur Verfügung.

Das Forschungsprojekt SOPHIE (Synchrone Produktion durch teilautonome Planung und humanzentrierte Entscheidungsunterstützung) befasst sich mit der Integration des Menschen in zukünftige Produktionssysteme. Ziel ist es, ein Entscheidungsunterstützungssystem zu entwickeln, welches die Stärken der Mitarbeiter (z. B. Umgang mit Unsicherheiten) nutzt. Gleichzeitig gilt es, die damit einhergehenden Anforderungen an die Informationsverarbeitung und Technologieakzeptanz zu berücksichtigen. Fokus des Projekts ist es, ausgehend von aktuellen Rückmeldedaten aus dem Produktionssystem, Simulationsläufe zur Evaluierung unter-

schiedlicher Handlungsalternativen zu veranlassen. Die bewerteten Handlungsalternativen sollen die Mitarbeiter bei ihren Entscheidungen unterstützen. Es wird ein dezentraler, agentenbasierter Ansatz für die Realisierung des Systems eingesetzt. Agenten werden sowohl für die Datenakquise als auch für das Starten der Simulationen zur Evaluierung der Handlungsalternativen eingesetzt. (MÜLLER & RIEDEL 2014, BLOCK ET AL. 2016)

Das Forschungsprojekt InnoCyFer hat sich zum Ziel gesetzt, Unternehmen zur Fertigung kundeninnovierter Projekte zu befähigen. Ein betrachteter Aspekt ist die PPS für eine Fertigung und Montage auf Basis von cyberphysischen Systemen. Neben den technischen Anforderungen wie bspw. der Verfügbarkeit von Echtzeitdaten sollen nutzerzentrierte Anforderungen ebenfalls berücksichtigt werden. Produktionsmitarbeiter erhalten die Planungs- und Steuerungsentscheidungen des entwickelten PPS-Systems und können im Bedarfsfall steuernd eingreifen. Unter Verwendung des Ameisenalgorithmus erfolgt die Erstellung einer Termin- und Kapazitätsplanung für die Fertigung. Insbesondere der Eintritt von unvorhergesehenen Ereignissen erfordert allerdings den Eingriff eines Produktionsmitarbeiters sowie die Auswahl einer Handlungsalternative ohne Unterstützung des entwickelten PPS-Systems. (VERNIM ET AL. 2014, WOLF ET AL. 2018)

2.8 Ableitung des Handlungsbedarfs

In den vorstehenden Abschnitten des Kapitels 2 ist der aktuelle Stand des Wissens dargestellt worden. Das Ziel war einerseits die kritische Würdigung bestehender Ansätze und andererseits die Identifizierung des Handlungsbedarfs mit Fokus auf die Produktionssteuerung. In Abschnitt 2.3 wurden dazu konventionelle und adaptive Ansätze zur Produktionssteuerung untersucht. Ein besonderes Augenmerk lag auf dem Einsatz von Agenten in Kombination mit regelbasierten Ansätzen wie auch Ansätzen aus den Bereichen RL und DRL (siehe Abschnitt 2.5.3). Das Interesse galt vor allem Ansätzen bzw. Systemen, welche im Kontext der Produktion und im Speziellen in der Produktionssteuerung eingesetzt werden. Weiter wurden in Abschnitt 2.6 Ansätze zur Erklärbarkeit von durch Systeme getroffene Entscheidungen untersucht. Abschnitt 2.7.3 behandelte unterschiedliche Ansätze zur Entscheidungsunterstützung im Rahmen der Produktion. Nachfolgend werden die aus der Auseinandersetzung mit Stand des Wissens gewonnenen Erkenntnisse nutzbar gemacht, um Handlungsbedarfe zur Potenzialsteigerung von Entscheidungsunterstützungssystemen im Kontext der Produktionssteuerung aufzuzeigen.

Zur zielgerichteten Unterstützung von Mitarbeitern in den komplexen Entscheidungssituationen der Produktionssteuerung kann ein System zur Entscheidungsunterstützung eingesetzt werden. Bei der Entwicklung eines solchen Systems müssen die vorhandene Organisationsstruktur und insbesondere die unterschiedlichen Entscheidungskompetenzen abgebildet und berücksichtigt werden. Deshalb bedarf es einer strukturierten Erfassung der relevanten Personen sowie ihrer Entscheidungskompetenz im Rahmen der Produktionssteuerung, die zur Steigerung sowohl der Benutzerfreundlichkeit als auch der Ausführungskonformität essenziell ist. Es gilt folglich, in Abhängigkeit von Benutzerrollen systematisch ein Informationsmodell zu erstellen, welches die Aufgaben sowie die notwendigen Informationen innerhalb der Produktionssteuerung transparent erfasst. Dies ermöglicht es, Mitarbeitern für konkrete Entscheidungen die relevanten Informationen sowie einen Entscheidungsvorschlag bereitzustellen. Ziel des zu entwickelnden Systems ist es, Unternehmen ein Raster vorzugeben, welches sie unternehmensspezifisch anpassen können.

Im Hinblick auf die Benutzerfreundlichkeit gilt es den Anforderungen, welche durch den Entscheidungsprozess der Mitarbeiter bei der Auswahl von Handlungsalternativen entstehen, gerecht zu werden. Dazu soll das zu entwickelnde System unterschiedliche Defizite im menschlichen Entscheidungsprozess adressieren. Ziel ist es, die individuelle Anpassung entsprechend der persönlichen Präferenz der Mitarbeiter zu ermöglichen.

Der kontinuierliche Anstieg der verfügbaren Rechenleistung sowie der im Zuge der Digitalisierung erfassten Datenmengen (LASI ET AL. 2014, AMODEI & HERNANDEZ 2018) ermöglicht die Beherrschung der wachsenden Komplexität in der Produktionssteuerung mithilfe rechenintensiver ML-Verfahren zur Entscheidungsfindung. Damit einerseits das Potenzial der Datenverarbeitung dieser Verfahren im Kontext der Produktionssteuerung genutzt werden kann und andererseits spezifische Entscheidungsfreiräume berücksichtigt werden können, bedarf es einer strukturierten und methodischen Ableitung von Agenten. Der Einsatz unterschiedlicher Agenten wiederum erfordert eine strukturierte Synthese unterschiedlicher Vorgehensweisen, um das Lernverhalten der Agenten positiv zu beeinflussen. Bei der Auswahl von Entscheidungen gilt es zusätzlich mehrere Kennzahlen entsprechend der unternehmensspezifischen Priorisierung zu berücksichtigen.

Eine Herausforderung für den Einsatz von ML-Verfahren im Produktionsumfeld ist das Vertrauen in von diesen Systemen erzeugte Handlungsempfehlungen. Es

fehlt hierbei an einem Ansatz, welcher einerseits die vom System generierten Entscheidungsvorschläge erklärbar aufbereitet und andererseits unterschiedliche Anforderungen der Benutzer berücksichtigt. Im Fokus dieser Arbeit steht deshalb die Verknüpfung von RL-basierten Ansätzen zur Entscheidungsunterstützung mit Ansätzen aus dem Bereich der XAI. Insbesondere sollen hierbei Endnutzer berücksichtigt und somit deren Vertrauen in systemische Entscheidungen erhöht werden. Ziel ist es, das Potenzial von RL-basierten Systemen zu nutzen und gleichzeitig die Anforderungen an die Benutzerfreundlichkeit und Informationsverdichtung unterschiedlicher Nutzer zu berücksichtigen.

Zusammenfassend ist festzuhalten, dass zur Hebung des Potenzials eines Systems zur Entscheidungsunterstützung in der Produktionssteuerung eine strukturierte Vorgehensweise notwendig ist. Diese muss die unterschiedlichen für die Produktionssteuerung relevanten Benutzer und deren Entscheidungskompetenzen identifizieren, abbilden und Defizite in ihrem Entscheidungsprozess adressieren. Darauf aufbauend gilt es ein methodisches Vorgehen zur Erstellung eines Systems zur Entscheidungsunterstützung zu entwickeln.

2.9 Fazit

Im Rahmen dieses Kapitels wurden aufbauend auf der Ausgangssituation und Zielsetzung der Arbeit die relevanten Grundlagen erörtert, zunächst jene aus dem Bereich der PPS. Diese beinhalten das Zielsystem der PPS, die Aufgaben der PPS sowie das Modell der Fertigungssteuerung, welches eine Verknüpfung der Aufgaben der PPS mit den Zielgrößen herstellt. Weiterhin wurden Agentensysteme eingeführt und deren Charakteristika beschrieben. Mit DRL wurde ein Verfahren aus dem Bereich des ML vorgestellt, welches es ermöglicht, basierend auf datenspezifischem Wissen zu generieren. Abschließend wurde anhand der Entscheidungstheorie im Allgemeinen und der grundlegenden Elemente eines Entscheidungsmodells im Speziellen der Bedarf an Unterstützungssystemen in der Produktion aufgezeigt. Mit Abschluss der im Rahmen dieses Kapitels durchgeführten Deskriptiven Studie wurden die Voraussetzungen für die im folgenden Kapitel beginnende Präskriptive Studie geschaffen.

3 Lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung

3.1 Allgemeines

Dieses Kapitel bildet den Beginn der *Präskriptiven Studie* der DRM. Ausgehend von der in Kapitel 1 beschriebenen Ausgangssituation sowie den identifizierten Herausforderungen wurde in Kapitel 2 der Stand des Wissens eingehend analysiert. In Abschnitt 2.8 erfolgte abschließend die Ableitung der Handlungsbedarfe. Ziel der folgenden präskriptiven Studie ist die Entwicklung eines Systems zur Adressierung identifizierter Handlungsbedarfe.

Hierfür werden zuerst Anforderungen an ein solches System definiert (siehe Abschnitt 3.2). Anschließend werden in Abschnitt 3.3 unterschiedliche zur Erfüllung der Anforderungen notwendige Systemelemente und die Interaktion zwischen ebendiesen vorgestellt. Abschließend werden die Systemelemente zusammengeführt und das daraus resultierende lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung beschrieben.

3.2 Anforderungen an ein lernendes und erklärbares System zur Entscheidungsunterstützung

Die Definition der im Folgenden aufgestellten Anforderungen an die Produktionssteuerung ist notwendig, um sicherzustellen, dass das System die Herausforderungen aktueller Produktionssysteme bewältigen kann. Insbesondere gilt es, die steigende Komplexität in der Produktion zu beherrschen (KLETTI & DEISENROTH 2021) und den Bedarf nach einer hohen Reaktionsfähigkeit zu erfüllen (KLETTI 2015b). Gleichzeitig gilt es, bei der Systementwicklung unterschiedliche Benutzer sowie deren Entscheidungsprozesse zu berücksichtigen, damit eine hohe Akzeptanz des Systems erreicht werden kann. Im Folgenden werden die aus den Handlungsbedarfen abgeleiteten Anforderungen an ein lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung definiert. Tabelle 3-1 zeigt eine Übersicht über diese Anforderungen.

Tabelle 3-1: Anforderungen an ein lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung

Nr.	Anforderungen
A.1	Übertragbarkeit und Skalierbarkeit
A.2	Zielgerichtete Informationsbereitstellung
A.3	Reaktionsfähigkeit auf unvorhergesehene Ereignisse
A.4	Berücksichtigung einer unternehmensindividuellen Zielfunktion
A.5	Hohe Lösungsgüte
A.6	Vollständige Durchsuchung des Lösungsraums
A.7	Erklärbarkeit von systemischen Entscheidungen

A.1 Übertragbarkeit und Skalierbarkeit

Die Übertragbarkeit auf andere Anwendungsfälle und die Skalierbarkeit des zu entwickelnden Systems sind zentrale Anforderungen. Einerseits wird durch die Übertragbarkeit gewährleistet, dass das zu entwickelnde System sowohl branchen- als auch unternehmensunabhängig ist. Voraussetzung für die Übertragbarkeit ist der Einsatz einer generischen Modellierungssprache. Andererseits muss die Skalierbarkeit des Systems gewährleistet sein. Dies erfordert eine einfache Erweiterungsmöglichkeit, bspw. durch einen modularen Aufbau. Außerdem gilt es darauf zu achten, dass die Skalierbarkeit nicht verfahrensbedingt eingeschränkt wird.

A.2 Zielgerichtete Informationsbereitstellung

Die Bereitstellung der „*richtigen Informationen in der richtigen Form zur richtigen Zeit am richtigen Ort*“ (NYHUIS ET AL. 2017) bildet die Grundlage einer performanten Produktionssteuerung. Voraussetzung für die gezielte Informationsbereitstellung ist die Identifikation der im Rahmen der Produktionssteuerung relevanten Benutzer bzw. Benutzerrollen. Diese gilt es bereits während der Systementwicklung zu berücksichtigen, damit ein nutzerzentriertes System entstehen kann.

A.3 Reaktionsfähigkeit auf unvorhergesehene Ereignisse

Zentraler Bestandteil der Produktionssteuerung ist die Umsetzung des Produktionsplans trotz in der Produktion unweigerlich auftretender unvorhergesehener Ereignisse. Deren Auftreten hat eine erhebliche Auswirkung auf die Erreichung der

logistischen Zielgrößen. Damit adäquat auf Ereignisse reagiert werden kann und somit deren Auswirkungen auf das Gesamtsystem möglichst gering gehalten werden können, ist eine hohe Reaktionsfähigkeit, oftmals innerhalb weniger Sekunden, unabdingbar.

A.4 Berücksichtigung einer unternehmensindividuellen Zielfunktion

Das von GUTENBERG (1971) beschriebene Dilemma der Ablaufplanung erfordert, unter Berücksichtigung unternehmensspezifischer Prioritäten, die Gewichtung der unterschiedlichen logistischen Zielgrößen. Dementsprechend muss die Zielfunktion einerseits multikriteriell und andererseits gewichtbar sein. Diese multikriterielle Zielfunktion gilt es bei der Maßnahmeninitiierung im Rahmen der Produktionssteuerung zu lösen.

A.5 Hohe Lösungsgüte

Eine hohe Güte der Lösungen des Systems ist einerseits für die Erfüllung der geplanten Zielgrößen und andererseits für das Vertrauen der Mitarbeiter in das System relevant. Durch die Produktionssteuerung wird der wirtschaftliche Erfolg eines Unternehmens wesentlich bestimmt (NYHUIS & WIENDAHL 2012). Deshalb ist es essenziell, die bestmöglichen Maßnahmen zu initiieren. Zusätzlich wird durch eine hohe Lösungsgüte das Vertrauen der Mitarbeiter in das System gestärkt (SABMANNSHAUSEN 2019). Durch eine geringe Lösungsgüte – repräsentiert durch fehlerhafte Handlungsvorschläge – hingegen nimmt das Vertrauen der Mitarbeiter in das System signifikant ab (YU ET AL. 2017, YIN ET AL. 2019).

A.6 Vollständige Durchsuchung des Lösungsraums

Durch den vermehrten Einsatz von Technologien zur Datenerfassung und -speicherung in der Produktion steigt die verfügbare Datenmenge. Dadurch ist ein immer besseres digitales Abbild des aktuellen Zustands des Produktionssystems möglich. Gleichzeitig steigt die Komplexität der Datenverarbeitung durch die Vergrößerung des durchsuchbaren Lösungsraums. Die Größe des Lösungsraums darf nicht verfahrensbedingt eingeschränkt werden.

A.7 Erklärbarkeit von systemischen Entscheidungen

Der Entscheidungsprozess des zu entwickelnden Systems muss nachvollziehbar sein, damit Nutzer des Systems Vertrauen in die erzeugten Entscheidungsvorschläge entwickeln (SABMANNSHAUSEN 2019). Durch ein gesteigertes Vertrauen in das System erhöht sich die Wahrscheinlichkeit, dass die Empfehlungen durch

Anwender umgesetzt werden. Zur Erreichung der definierten Zielgrößen ist dies elementar.

3.3 Systemelemente

Im Folgenden sollen die Systembausteine, wie in Abbildung 3-1 dargestellt, vorgestellt werden. Die Systembausteine *benutzerrollenspezifisches Informationsmodell*, *lernende benutzerrollenspezifische Produktionssteuerung* sowie *Erklärbarkeit von systemischen Entscheidungen* werden in den Kapiteln 4, 5 und 6 detailliert beschrieben.

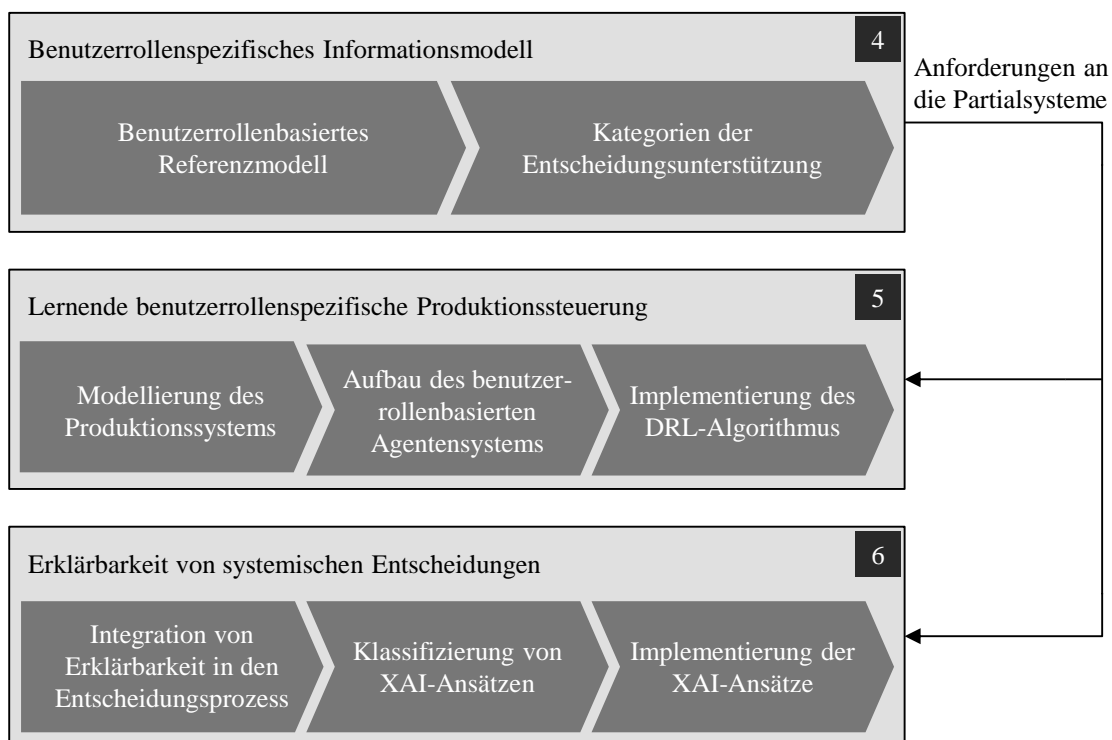


Abbildung 3-1: Überblick über das lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung

Das *benutzerrollenspezifische Informationsmodell* ist die Grundlage für die weiteren Systembausteine. Im Rahmen dieses Bausteins wird zuerst die Entwicklung eines Referenzmodells zur Beschreibung unterschiedlicher Benutzerrollen im Kontext der Produktionssteuerung mit Hilfe eines strukturierten methodischen Vorgehens beschrieben. Hierbei liegt der Fokus auf der Identifizierung der durch die jeweilige Benutzerrolle initiierten Maßnahmen im Rahmen der Produktions-

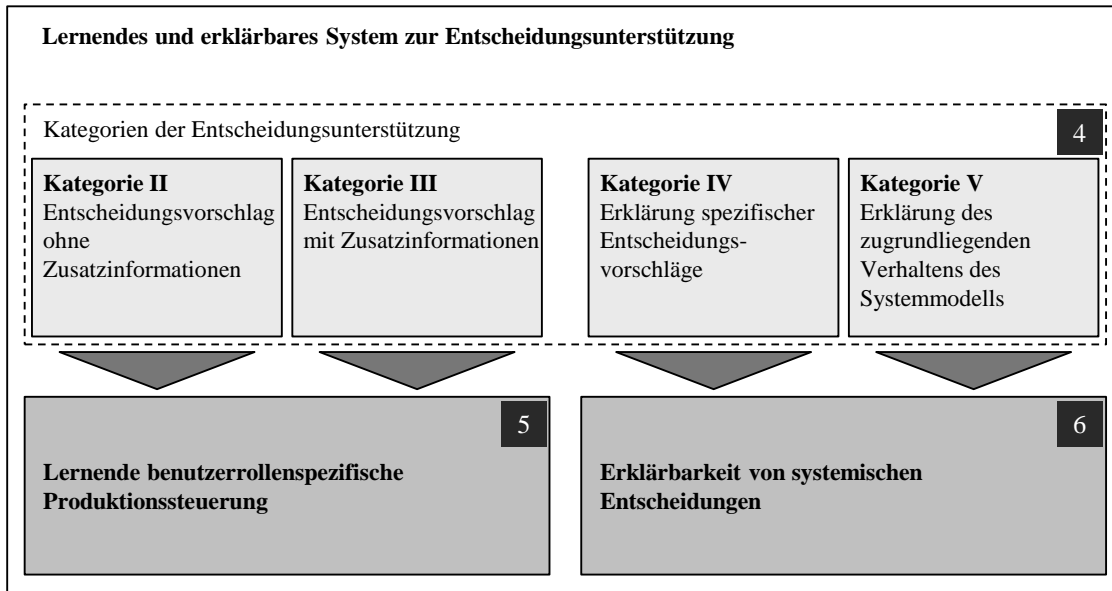
steuerung. Zusätzlich sollen die Defizite des menschlichen Entscheidungsprozesses analysiert werden. Mit Hilfe unterschiedlicher Kategorien der Entscheidungsunterstützung sollen diese Defizite abgeschwächt werden. Hiermit wird es den Anwendern ermöglicht, sich entsprechend der eigenen Präferenz sowie Vorkenntnisse einzuordnen und dadurch den Grad der benötigten Unterstützung zu definieren.

Die *lernende benutzerrollenspezifische Produktionssteuerung* beinhaltet die Entwicklung einer DRL-basierten, benutzerrollenspezifischen Produktionssteuerung. Auf Grundlage des entwickelten benutzerrollenspezifischen Informationsmodells ist der erste Schritt hierfür die Modellierung unterschiedlicher Agenten, die sowohl den möglichen Aktionsraum (z. B. Reihenfolgevertauschung) als auch die Verortung im bestehenden Produktionssystem (z. B. Bediener einer Verpackungsanlage) beinhaltet. Abschließend erfolgt die gezielte Anpassung und Implementierung eines geeigneten DRL-Lernverfahrens, damit das agentenbasierte Produktionssteuerungssystem die bestmögliche Aktion in Abhängigkeit vom aktuellen Zustand des Produktionssystems vorschlagen kann.

Die Anforderungen der Benutzer an den Entscheidungsprozess werden durch die Integration einer adaptiven, benutzerrollenzentrierten *Erklärbarkeit* in das System zur Entscheidungsunterstützung berücksichtigt. Hierfür werden zuerst unterschiedliche Erklärbarkeitsansätze im Kontext von DRL diskutiert. Die ausgewählten Ansätze für die Erklärbarkeit werden im letzten Schritt in das System zur Entscheidungsunterstützung integriert. Hierdurch ist die Erklärbarkeit sowohl von einzelnen Entscheidungen (lokale Erklärbarkeit) als auch des gesamten Modells (globale Erklärbarkeit) gegeben. Ziel dieser Erklärbarkeit ist die Steigerung des Vertrauens der Mitarbeiter in die vom System vorgeschlagenen Maßnahmen.

Abbildung 3-2 zeigt die im Rahmen des lernenden und erklärbaren System zur Entscheidungsunterstützung entwickelten Kategorien der Entscheidungsunterstützung sowie den Zusammenhang mit den Partialsystemen. Die Realisierung der Kategorien II und III ist Aufgabe des Partialsystems *lernende benutzerrollenspezifische Produktionssteuerung*. Die Kategorien IV und V werden hingegen durch das Partialsystem *Erklärbarkeit von systemischen Entscheidungen* umgesetzt.

3 LERNENDES UND ERKLÄRBARES SYSTEM ZUR ENTSCHEIDUNGSUNTERSTÜTZUNG IN DER PRODUKTIONSSTEUERUNG



Legende:

□ : Kategorien der Entscheidungsunterstützung □ : Partialsystem

Abbildung 3-2: Zusammenhang der definierten Kategorien der Entscheidungsunterstützung und der Partialsysteme *lernende benutzerrollenspezifische Produktionssteuerung* und *Erklärbarkeit von systemischen Entscheidungen*

4 Benutzerrollenspezifisches Informationsmodell

4.1 Allgemeines

Im Rahmen dieses Kapitels wird das entwickelte benutzerrollenspezifische Informationsmodell beschrieben. Es bildet die Grundlage für und stellt Anforderungen an die weiteren Partialsysteme, welche in den Kapiteln 5 und 6 detailliert werden. Ziel des benutzerrollenspezifischen Informationsmodells ist es einerseits, die für die Produktionssteuerung relevanten Benutzerrollen sowie deren Handlungsraum zu identifizieren. Andererseits gilt es, Einflussfaktoren des menschlichen Entscheidungsprozesses und die daraus resultierenden Defizite zu analysieren, um diese mit Hilfe des Systems zur Entscheidungsunterstützung bestmöglich zu mitigieren. Für das Erstellen des benutzerrollenspezifischen Informationsmodells wird zuerst ein Referenzmodell erstellt (Abschnitte 4.2 und 4.3). In Abschnitt 4.5 wird anschließend ein Vorgehen konzipiert, wie das Referenzmodell unternehmensspezifisch angepasst werden kann. Durch diese Anpassungen entsteht das unternehmens- und benutzerrollenspezifische Informationsmodell.

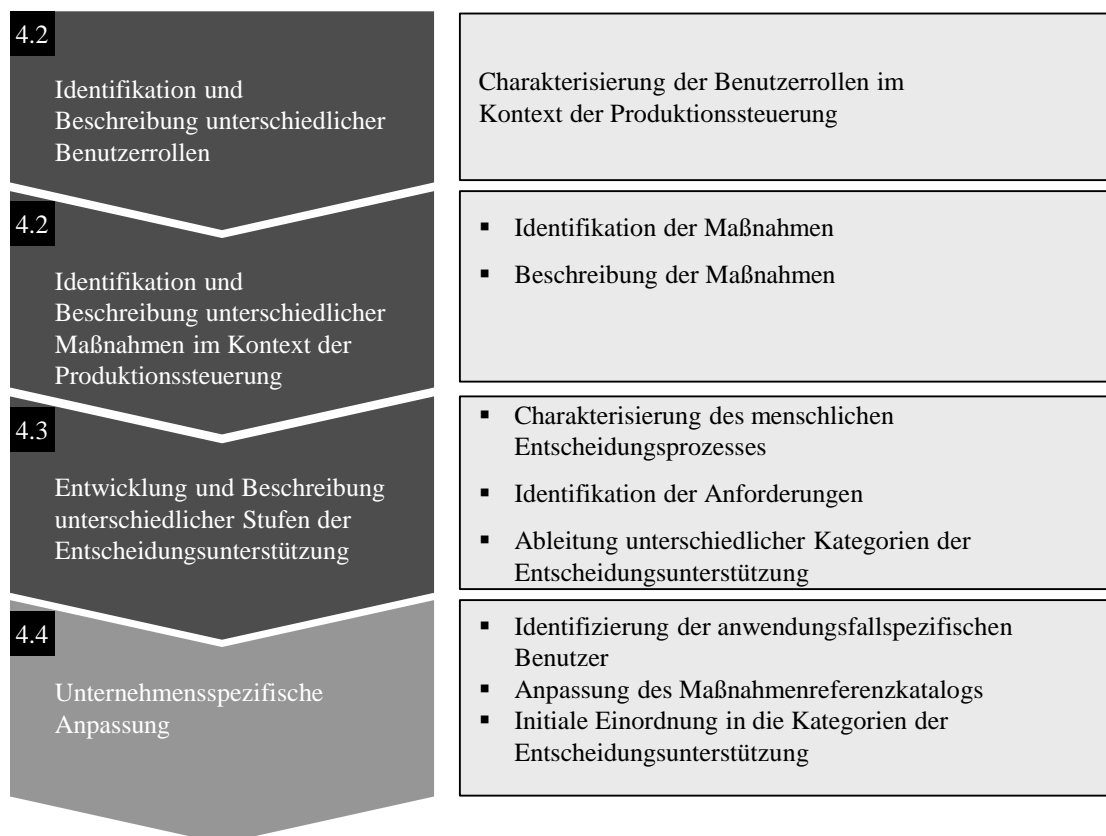
Referenzmodelle werden nach FETTKE & LOOS (2004a) *„zur inhaltlichen Unterstützung bei der Erstellung von Anwendungsmodellen entwickelt oder genutzt. Kennzeichnendes Merkmal eines Referenzmodells ist ihre potenzielle oder faktische Wiederverwendung in anderen Modellierungskontexten“* (FETTKE & LOOS 2004a). Referenzmodelle sind durch die charakteristischen Eigenschaften

- Allgemeingültigkeit,
- leichte Anpassbarkeit,
- Empfehlungscharakter,
- Vollständigkeit,
- Korrektheit und
- Verständlichkeit

gekennzeichnet (FETTKE & LOOS 2004b, VOM BROCKE 2015). Durch eine unternehmens- bzw. anwendungsfallsspezifische Anpassung des Referenzmodells entsteht ein Anwendungs- bzw. Informationsmodell (FETTKE & LOOS 2004b).

Für die Erstellung des benutzerrollenspezifischen Informationsmodells sind unterschiedliche Schritte notwendig (siehe Abbildung 4-1). Zuerst wird ein Referenz-

modell erstellt. Dies beinhaltet die Definition des *Nutzungskontexts* und des *Unterstützungsbedarfs*. Für die Beschreibung des Nutzungskontexts werden die für die Produktionssteuerung relevanten Benutzerrollen identifiziert und anschließend unterschiedliche Nutzungsszenarien für die jeweiligen Benutzerrollen beschrieben. Anschließend wird ein *Maßnahmenreferenzkatalog* entwickelt, welcher Maßnahmen beinhaltet, die im Rahmen der Produktionssteuerung initiiert werden können. Damit ein Informationssystem Nutzern in Abhängigkeit von deren individueller Präferenz die geforderten Informationen (inkl. Zusatzinformationen) liefern kann, gilt es unterschiedliche Ausprägungen der Entscheidungsunterstützung zu konzeptionieren. Dadurch sollen die Defizite des menschlichen Entscheidungsprozesses adressiert werden. Entsprechend diesen Kategorien können unterschiedliche Arten der Entscheidungsunterstützung realisiert werden. Hierfür werden un-



Legende:



Abbildung 4-1: Vorgehen zur Erstellung eines benutzerspezifischen Informationsmodells

terschiedliche *Kategorien der Entscheidungsunterstützung* definiert und beschrieben. Abschließend wird erläutert, wie durch die Anpassung des entwickelten Referenzmodells ein unternehmens- und benutzerrollenspezifisches Informationsmodell erstellt werden kann. Dieses ermöglicht die Beschreibung der an Entscheidungssituationen der Produktionssteuerung beteiligten Benutzer sowie eine initiale Einordnung ihres Unterstützungsbedarfs. Das Ergebnis dieses Schritts ist ein Informationsmodell, welches sowohl die Maßnahmen als auch den zugehörigen Informationsbedarf für die jeweiligen Benutzerrollen beschreibt.

4.2 Nutzungskontext

Der Nutzungskontext entsprechend DIN EN ISO 9241-210 beinhaltet eine Beschreibung der *Benutzer*, der *Benutzermerkmale*, der *Aufgaben* und *Ziele* der Benutzer sowie Informationen über die *Systemumgebung*. Der Benutzer wird in der DIN EN ISO 9241-11 als „*Person, die mit einem System, einem Produkt oder einer Dienstleistung interagiert*“, bezeichnet. Benutzergruppe und Benutzerrolle, welche teilweise synonym verwendet werden, bezeichnen eine „*Untergruppe von vorgesehenen Benutzern, die anhand von Merkmalen der Benutzer, Aufgaben oder Umgebungen [...] von anderen vorgesehenen Benutzern abgegrenzt wird*“ (DIN EN ISO 9241-11). Im Rahmen dieser Arbeit wird der Terminus *Benutzerrolle* verwendet. Der Fokus dieser Arbeit liegt nicht auf der Detaillierung jedes einzelnen Benutzers, sondern es gilt die für die Produktionssteuerung relevanten Benutzerrollen zu identifizieren. Diese wiederum können für die unternehmensspezifische Anpassung weiter detailliert werden (z. B. Anlagenbediener einer spezifischen Anlage).

4.2.1 Benutzerrollen

Das Formulieren von Benutzerrollen ist ein Modellierungselement, welches in der Softwareentwicklung eingesetzt wird. Das Ziel der Identifizierung unterschiedlicher Benutzerrollen ist es, die Interaktionen und Anforderungen unterschiedlicher Systemnutzer zu erfassen. Damit ist es möglich, ein System zielgerichtet und unter Berücksichtigung der Anforderungen unterschiedlicher Benutzer zu entwickeln. Bei der Modellierung von Benutzerrollen werden Charakteristika sowie beabsichtigte Systeminteraktionen von unterschiedlichen Benutzern erfasst. (COHN 2004)

Eine Benutzerrolle setzt sich aus einer spezifischen Bezeichnung und einer optionalen Beschreibung zusammen (COHN 2004, RICHTER 2018). Die Definition von

Benutzerrollen kann durch den Einsatz von Kreativitätstechniken (z. B. Brainstorming) oder ausgehend von tatsächlich in einem Produktionssystem vorhandenen Benutzerrollen (COHN 2004) realisiert werden. Spezifische Benutzerrollen können ebenfalls aus übergeordneten Benutzerrollen abgeleitet werden. Hierdurch wird der Aufbau eines hierarchischen Systems ermöglicht, welches die Repräsentation einer Aufgabenteilung sowie einer geteilten Verantwortung für spezifische Aufgaben erlaubt. (RICHTER 2018) Die Betrachtung und Beschreibung der Benutzerrollen ermöglicht zudem eine nutzerzentrierte Informationsbereitstellung. Im Kontext der Produktionssteuerung bedeutet dies, dass die richtige Person die richtigen Informationen erhält, welche zur Entscheidungsfindung bei der Maßnahmenauswahl (z. B. Vorziehen eines Arbeitsvorgangs) notwendig sind.

Identifikation von Benutzerrollen mit Fokus auf die Produktionssteuerung

In Abbildung 4-2 sind die unterschiedlichen Benutzerrollen sowie unterschiedliche Ausprägungen von charakteristischen Merkmalen aufgeführt. Ausgehend von einer Literaturrecherche wurden abstrakte Benutzerrollen definiert, welche in einem Produktionssystem auftreten können und an der Steuerung der Produktion partizipieren. Zu den Bezeichnungen der Benutzerrollen ist hervorzuheben, dass es sich ausschließlich um eine auf einer Literaturrecherche basierende initiale Auflistung handelt. Bezeichnungen können von Unternehmen zu Unternehmen stark variieren und sind deshalb unternehmensspezifisch anzupassen. Entsprechend DIN EN ISO/IEC 25063 können mit einem System interagierende Benutzer als primäre und sekundäre Benutzer klassifiziert werden. Die Interaktion von primären Benutzern ist unmittelbar und dient der Erfüllung des Einsatzzwecks des Systems. Sekundäre Benutzer hingegen wirken unterstützend und übernehmen bspw. Verwaltungs- oder Wartungsaufgaben (DIN EN ISO/IEC 25063). Aufgrund

Benutzerrolle	Produktions-leiter	Produktions-planer	Produktions-steuerer	Meister	Anlagen-bediener
Aggregationsebene	Fabrik	Segment	System	Zelle	Arbeitsstation
Betrachtungsraum	Vertikal		Horizontal		Hybrid
Tätigkeitsprofil	Operativ		Dispositiv		Hybrid

Abbildung 4-2: Morphologischer Kasten für unterschiedliche Benutzerrollen sowie deren unterschiedliche Ausprägungen

des Fokus dieser Arbeit auf die Produktionssteuerung werden im Folgenden ausschließlich primäre Benutzer aufgeführt.

Aggregationsebene

Für die Beschreibung der Benutzerrollen ist es wichtig, deren Wirkungsbereich im Produktionssystem zu bestimmen. Das Produktionssystem kann entsprechend der Ressourcensicht von WIENDAHL ET AL. (2007) in die Aggregationsebenen *Fabrik*, *Segment*, *System*, *Zelle* und *Arbeitsstation* eingeteilt werden (siehe Abbildung 4-3). Eine Fabrik ist im Rahmen dieser Arbeit die höchste betrachtete Aggregationsstufe. Sie besteht aus mehreren Segmenten. Innerhalb eines Segments werden typischerweise Produkte vollständig gefertigt. Ein Segment kann weiter in Arbeitssysteme unterteilt werden, welche durch eine Verknüpfung von Zellen charakterisiert sind. Charakteristisch für eine Zelle ist, dass notwendige Bearbeitungs- und Montageschritte – unter Aufbringung eines entsprechenden Ressourceneinsatzes (Anlagen und/oder Mitarbeiter) – durchgeführt werden. Die einzelnen Bearbeitungs- und Montageschritte werden innerhalb von Arbeitsstationen ausgeführt. Im Rahmen dieser Arbeit ist die Arbeitsstation die kleinste betrachtete Aggregationsebene.

Die tatsächlichen Systemgrenzen der Produktionssteuerung können in Abhängigkeit vom spezifischen Anwendungsfall variieren. Aufgrund der Fokussierung der Arbeit auf die innerbetriebliche Produktionssteuerung werden für die initiale Einordnung unterschiedlicher Benutzerrollen die aufgeführten Aggregationsstufen gewählt. Falls aufgrund unternehmensspezifischer Anforderungen eine standortübergreifende Betrachtung erforderlich ist, kann diese Kategorie ergänzt werden. Durch die Einteilung der unterschiedlichen Benutzerrollen in die Aggregate können in der Fabrik bestehende hierarchische Strukturen berücksichtigt werden. Die Zuordnung der Aggregationsebenen erfolgt entsprechend des Handlungsspielraums, welchen die jeweiligen Benutzerrollen besitzen. Ein Anlagenbediener bspw. beeinflusst ausschließlich die ihm zugeteilte Anlage direkt. Somit ist sein Betrachtungsraum gleichzusetzen mit der Arbeitsstation. Ein Produktionssteuerer hingegen kann tendenziell unterschiedliche Aggregationsebenen beeinflussen. Hier muss eine Differenzierung entsprechend der Auswirkung der Maßnahmen, welche im Rahmen der Produktionssteuerung ergriffen werden können, erfolgen.

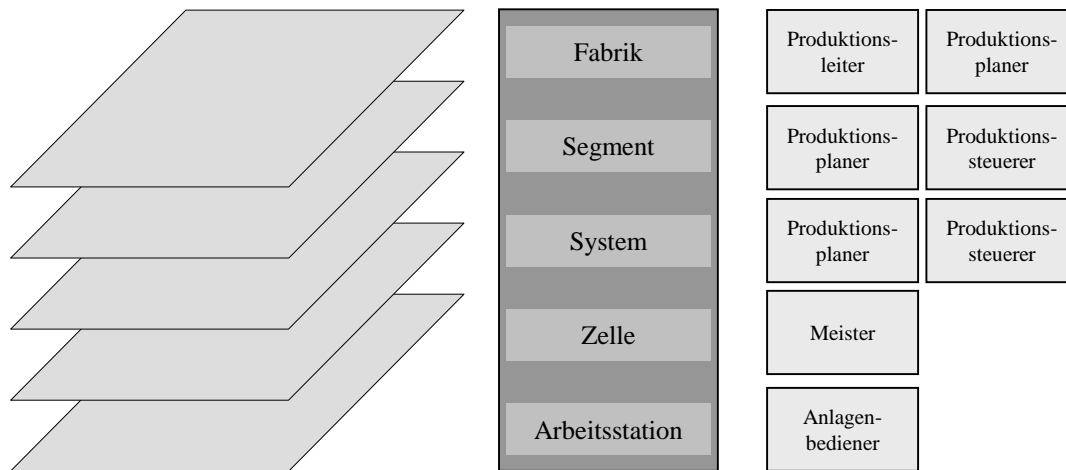


Abbildung 4-3: Initiale Zuordnung der Benutzerrollen zu den Ebenen der Fabrik

Betrachtungsraum

Demgegenüber entspricht der *Betrachtungsraum* der Informationsgrundlage, welche die Benutzerrollen für Entscheidungen im Rahmen der Produktionssteuerung erhalten bzw. benötigen. Die Informationen können entweder von der gleichen Aggregationsebene oder von einer abweichenden Aggregationsebene (z. B. Störung innerhalb einer anderen Zelle) stammen. Bei den Informationen aus der gleichen Aggregationsebene gilt es zu differenzieren, ob es sich um Informationen zum betrachteten Element handelt (z. B. Sensorwerte der zugeordneten Anlage) oder um Informationen zu vor- oder nachgelagerten Elementen (z. B. einer vor- oder nachgelagerten Arbeitsstation innerhalb derselben Zelle). Eine Mischform beider Betrachtungsräume (hybrid) ist ebenfalls möglich.

Tätigkeitsprofil

Ergänzend kann eine Klassifizierung der Benutzerrollen bzgl. der Tätigkeitsprofile vorgenommen werden. Hierbei gilt es zwischen operativen und dispositiven Tätigkeitsschwerpunkten zu unterscheiden (HIRSCH-KREINSEN 2015, WISCHMANN & HARTMANN 2018a). Bei operativen Tätigkeitsprofilen liegt der Arbeitsschwerpunkt auf ausführenden Tätigkeiten, welche für die Herstellung eines Produkts notwendig sind. Aufgaben, welche einem dispositiven Tätigkeitsprofil zuordenbar sind, sind das Planen, Organisieren, Steuern und Kontrollieren von Produktionsabläufen. (WISCHMANN & HARTMANN 2018b) Auch wenn der Trend sich hin zu

einer personellen Trennung von operativen und dispositiven Tätigkeiten entwickelt (WISCHMANN & HARTMANN 2018a), sind gemischte bzw. hybride Tätigkeitsprofile weiterhin relevant.

4.2.2 Maßnahmenreferenzkatalog

Der Nutzungskontextbeschreibung nach DIN EN ISO/IEC 25063 folgend wird im Weiteren ein Maßnahmenreferenzkatalog erstellt. Er beinhaltet Maßnahmen, die im Rahmen der Produktionssteuerung ausgeführt werden können, um in den Produktionsablauf steuernd einzugreifen. Der Fokus liegt hierbei auf den Hauptaufgaben der Produktionssteuerung *Auftragsfreigabe*, *Kapazitätssteuerung* und *Reihenfolgebildung*.

Der Maßnahmenreferenzkatalog bildet einen allgemeingültigen Rahmen, welcher dazu dient, den initialen Aufwand bei der Identifizierung spezifischer Maßnahmen für die Produktionssteuerung zu reduzieren. In Abbildung 4-4 sind die Charakteristika zu sehen, aus welchen der Maßnahmenreferenzkatalog besteht. Die zur Detaillierung der Maßnahmen verwendeten charakteristischen Merkmale *Informationsbedarf*, *Ziele und Auswirkungen*, *Voraussetzung* sowie *Auslöser* werden im Folgenden näher erläutert.




Abbildung 4-4: Struktur des Maßnahmenreferenzkatalogs

Maßnahmen der Produktionssteuerung

Im Folgenden werden Maßnahmen beschrieben, welche im Rahmen der Produktionssteuerung zur Beeinflussung des Produktionsablaufs ergriffen werden können. Hierbei erfolgt eine Unterteilung der Aufgaben der Produktionssteuerung entsprechend dem Modell der Fertigungssteuerung nach LÖDDING (2016). Die Auftragsfreigabe bestimmt den zeitlichen Zugang von Aufträgen zum Produktionssystem. Ziel der Kapazitätssteuerung ist die Beeinflussung des Ist-Abgangs des Produkti-

onssystem durch die Veränderung der Ressourcenintensität. Die Reihenfolgebildung definiert die Abarbeitungsreihenfolge der Aufträge an einem Arbeitssystem. (LÖDDING 2016) Tabelle 4-1 beinhaltet eine Übersicht über die Maßnahmen der Produktionssteuerung. Für eine detaillierte Beschreibung der einzelnen Maßnahmen sei auf TRZYNA 2015, LÖDDING 2016, PIELMEIER 2019, WIENDAHL & WIENDAHL 2019 und SCHMIDT & NYHUIS 2021c verwiesen.

Tabelle 4-1: Übersicht über unterschiedliche Maßnahmen der Auftragsfreigabe, Kapazitätssteuerung und Reihenfolgebildung (i. A. an TRZYNA 2015, LÖDDING 2016, PIELMEIER 2019, WIENDAHL & WIENDAHL 2019, SCHMIDT & NYHUIS 2021c)

Auftragsfreigabe	Kapazitätssteuerung	Reihenfolgebildung
Veränderung der Intensität des Ist-Zugangs	Veränderung der Betriebsmittelintensität	Rüstzeitoptimierende Reihenfolgebildung
Änderung des Zeitpunkts der Auftragsfreigabe	Verschiebung von Wartungsarbeiten	Right-Shifting and Jumping
Austausch von Aufträgen zwischen Planungsperioden	Verlagerung auf alternative Betriebsmittel	Vorziehen von Arbeitsvorgängen, Left-Shifting
	Flexibilisierung der Arbeitsgeschwindigkeit	Zusammenfassung von Arbeitsvorgängen
	Mehrfachqualifikation	Priorisierung von Arbeitsvorgängen
	Überlappende Fertigung	

Informationsbedarf

Zunächst ist zu definieren, welche Informationen benötigt werden, um eine Maßnahme zielgerichtet auslösen zu können. Dieser Informationsbedarf (z. B. Informationen zu Aufträgen, Beständen und/oder Kapazitäten) kann entsprechend den angedachten Maßnahmen stark variieren und in der Granularität (z. B. Auslastung einer Produktionszelle gegenüber Auslastung eines Produktionssegments) unterschiedliche Ausprägungen annehmen. Einen signifikanten Einfluss auf den Informationsbedarf hat auch die Benutzerrolle, für welche die jeweilige Maßnahme vorgesehen ist.

Ziel und Auswirkungen

Mit diesem Merkmal wird das Ziel erfasst, welches durch das Initiieren der Maßnahmen verfolgt wird. Die Auswirkungen beinhalten die Kennzahlen, welche durch das Auslösen einer Maßnahme beeinflusst werden. Die Auswirkungen von Maßnahmen auf relevante Kennzahlen können Anhang 14.1 entnommen werden. Entsprechend dem Dilemma der Ablaufplanung (siehe Abschnitt 2.3.1) sind die logistischen Zielgrößen gegenläufig und es gilt die Auswirkungen von Maßnahmen auf unterschiedliche Kenngrößen zu berücksichtigen.

Voraussetzungen

Im Rahmen der Voraussetzungen wird beschrieben, welche Voraussetzungen (z. B. Verfügbarkeit einer Ressource) erfüllt sein müssen, damit die entsprechende Maßnahme umgesetzt werden kann.

Auslöser

Maßnahmen können im Rahmen der Produktionssteuerung infolge unterschiedlicher Auslöser unterteilt werden. Einerseits können Maßnahmen der Produktionssteuerung periodisch zu einem definierten Zeitpunkt und andererseits ereignisorientiert ergriffen werden. Ein definiertes Ereignis (z. B. eine Anlagenstörung) dient in diesem Fall als Auslöser.

4.3 Kategorien der Entscheidungsunterstützung

Ziel dieser Arbeit ist es, den Mitarbeiter in unterschiedlichen Entscheidungssituationen im Rahmen der Produktionssteuerung zu unterstützen. In Abhängigkeit von der Benutzerrolle und vom individuellen, dieser Benutzerrolle zugehörigen Benutzer kann der notwendige Entscheidungsunterstützungsbedarf variieren. Im Rahmen dieses Abschnitts steht die Definition unterschiedlicher Kategorien der Entscheidungsunterstützung im Fokus. Hierfür erfolgt in einem ersten Schritt die Beschreibung der Entscheidungsfindung von Personen. Dazu werden Charakteristika und Defizite der Entscheidungsfindung identifiziert. Daraufhin werden Anforderungskriterien der Entscheidungsunterstützung abgeleitet. Diese dienen anschließend als Ausgangspunkt für die Differenzierung unterschiedlicher Kategorien der Entscheidungsunterstützung zur Mitigation der identifizierten Defizite.

4.3.1 Duale Architektur der Entscheidungspsychologie

Zur Bestimmung des Unterstützungsbedarfs ist eine Analyse des tatsächlichen Entscheidungsverhaltens von Personen notwendig. Im Rahmen dieser Arbeit erfolgt dies mit Hilfe der deskriptiven Entscheidungstheorie, die das tatsächliche Entscheidungsverhalten von Personen beschreibt und analysiert (siehe Abschnitt 2.7). Im Folgenden wird die der deskriptiven Entscheidungstheorie zuordenbare duale Architektur der Entscheidungspsychologie von TVERSKY & KAHNEMAN (1974) vorgestellt.

Kognitive und affektive Prozesse, welche vom automatisch-unbewussten bis kontrolliert-bewussten Ausführen von Handlungen reichen, können in zwei Kategorien eingeteilt werden. Die so entstehende duale Architektur der Entscheidungspsychologie beschreibt zwei qualitativ differierende Systeme, anhand derer Personen in Entscheidungssituationen die Auswahl einer Handlungsalternative treffen. (STANOVICH & WEST 2000, PFISTER ET AL. 2017)

STANOVICH & WEST (2000) haben das sogenannte System-1/System-2-Modell zur Beschreibung des Entscheidungsprozesses entwickelt. Die dem System 1 zugeordneten kognitiven Prozesse sind automatisch, schnell, mühelos und unterbewusst. Entscheidungen werden hierbei häufig basierend auf Erfahrungen getroffen. Das Anwenden einer einfachen kognitiven Heuristik zur Entscheidungsfindung kann bspw. dem System 1 zugeordnet werden. (TVERSKY & KAHNEMAN 1974, KAHNEMAN 2012, PFISTER ET AL. 2017) Eine Heuristik beschreibt eine einfache, teilweise erfahrungsbasierte Regel, welche zur Entscheidungsfindung herangezogen wird (PFISTER ET AL. 2017).

Das System 2 beinhaltet kognitive Prozesse, welche bewusst, kontrolliert und langsam ablaufen sowie durch einen tendenziell längeren Entscheidungsfindungsprozess gekennzeichnet sind. Aufgrund dieser Charakteristika wird das System 2 mit rationalen und analytischen Entscheidungen assoziiert. (TVERSKY & KAHNEMAN 1974, KAHNEMAN 2012, PFISTER ET AL. 2017) Die simple Addition zweier niedriger Zahlen (z. B. $3 + 3$) erfolgt mühelos und schnell. Somit kann das Lösen dieser Aufgabe dem System 1 zugeordnet werden, wohingegen die Multiplikation zweier hoher Zahlen (z. B. $23 * 42$) nicht mühelos und schnell erfolgt, sondern eine Abfolge von Rechenoperationen erfordert. Aufgrund dieser Eigenschaft ist dieses Beispiel dem System 2 zuzuordnen. (KAHNEMAN 2012) Tabelle 4-2 zeigt eine Übersicht über die mit den beiden Systemen assoziierten Charakteristika von Entscheidungsfindungsprozessen.

Zwischen den beiden Systemen existieren Abhängigkeiten, welche ein voneinander unabhängiges Funktionieren nicht ermöglichen (KAHNEMAN 2012, PFISTER ET AL. 2017). Entsprechend der zu lösenden Situation variiert der Grad der Beanspruchung des jeweiligen Systems. System 1 kann als das Standardsystem für Entscheidungen betrachtet werden (PFISTER ET AL. 2017) und arbeitet automatisch und reaktiv, allerdings nicht optimierend (SHLEIFER 2012). Es ist kontinuierlich im Einsatz und erzeugt Wahrnehmungen, Eindrücke, Bewertungen und Entscheidungen. In der Regel werden die Entscheidungen von System 1 adaptiert und es wird in Übereinstimmung mit ihnen gehandelt. System 2 dient als Interventionsinstanz. In Situationen, in welchen System 1 seine Grenzen erreicht, wird das System 2 beansprucht. Dies geht einher mit einer bewussten Analyse der Situation und dem überlegten Treffen von Entscheidungen. (KAHNEMAN 2012, PFISTER ET AL. 2017)

Tabelle 4-2: Charakteristika des System-1/System-2-Modells (STANOVICH ET AL. 2014)

System 1	System 2
Schnell	Langsam
Häufig unterbewusst	Häufig bewusst
Automatisch	Kontrolliert
Implizit	Explizit
Geringer kognitiver Aufwand	Kognitive Anstrengung notwendig

Divergieren die Wahrnehmungen und Präferenzen beider Systeme, entsteht eine Konfliktsituation zwischen den reaktiven Impulsen und dem rationalen Verhalten. Die Aufteilung von Entscheidungen zwischen System 1 und System 2 resultiert in der Regel mit einem möglichst geringen kognitiven Aufwand bei gleichzeitiger hoher Performanz. Allerdings existieren kognitive Bias¹⁴ (z. B. eine verzerrte Wahrnehmung einer Entscheidungssituation), welche zu Fehlentscheidungen führen (KAHNEMAN 2012, SHLEIFER 2012). Diese werden im Folgenden detailliert beschrieben. Daraus abgeleitet ergeben sich die Anforderungen an das im Rahmen dieser Arbeit entwickelte System.

¹⁴ Bias = „durch Voreingenommenheit verzerrte Wahrnehmung oder Einschätzung“ (DUDENREDAKTION 2023).

Die am Produktionsablauf beteiligten Mitarbeiter müssen in Abhängigkeit von ihrer Benutzerrolle unterschiedliche Steuerungsentscheidungen treffen. Diese Entscheidungen sind häufig mit einer hohen Komplexität sowie einem hohen Zeitdruck assoziiert (KLETTI & DEISENROTH 2021). Gleichzeitig haben die Entscheidungen einen direkten Einfluss auf die logistischen Zielgrößen und dadurch auf die Wirtschaftlichkeit des Unternehmens. In Abhängigkeit vom Ablauf des Entscheidungsfindungsprozesses (System 1 oder System 2) ergeben sich unterschiedliche Bias, welche es mit Hilfe eines Systems zur Entscheidungsunterstützung abzumildern gilt. Im Folgenden werden zuerst die Charakteristika der Entscheidungsfindung unter Berücksichtigung des System-1/System-2-Modells beschrieben. Anschließend erfolgt die Beschreibung der Defizite des jeweiligen Entscheidungsprozesses.

Entscheidungen, welche unter Verwendung einfacher Heuristiken spontan und intuitiv getroffen werden, können häufig gute Ergebnisse liefern. Prinzipiell ist die Güte dieser Entscheidungen allerdings stark von der jeweiligen Person und deren Wissen abhängig. Diese Art von Entscheidungen kann auch zu schwerwiegenden Fehleinschätzungen führen, die in der Regel nicht zufällig auftreten. Vielmehr handelt es sich um ein Bias. (PFISTER ET AL. 2017) Prinzipiell kann nach TVERSKY & KAHNEMAN (1974) eine Unterscheidung in drei Kategorien von Heuristiken vorgenommen werden, die jeweils für unterschiedliche Arten von Bias anfällig sind. Die *Repräsentativitätsheuristik* beschreibt die Einschätzung, dass ein Ereignis *E* zu einer Kategorie *A* gehört. Ist die Ähnlichkeit von *E* zu einem typischen Ereignis der Kategorie *A* hoch, so wird die Wahrscheinlichkeit der Zugehörigkeit von *E* zu *A* intuitiv als hoch eingestuft. (TVERSKY & KAHNEMAN 1974, KAHNEMAN 2012, PFISTER ET AL. 2017) Die *Verfügbarkeitsheuristik* beschreibt, dass die Wahrscheinlichkeitsbeurteilung – und dadurch die Auswahl einer Entscheidung – abhängig von der Leichtigkeit ist, mit welcher eine Person sich an eine Vielzahl ähnlicher Ereignisse erinnern bzw. sich eine Vielzahl ähnlicher Situationen vorstellen kann. (TVERSKY & KAHNEMAN 1974) Die dritte Heuristik, *Verankerung und Anpassung*, beschreibt die Beeinflussung von Entscheidungen durch den jeweiligen Ausgangspunkt. Der Ausgangspunkt kann z. B. die Problembeschreibung oder ein Zwischenergebnis sein. Basierend darauf erfolgt eine Anpassung des Wahrscheinlichkeitsurteils. (TVERSKY & KAHNEMAN 1974) In Tabelle 4-3 werden die Bias nach TVERSKY & KAHNEMAN (1974) aufgeführt, welche für die jeweilige Heuristik charakteristisch sind.

Tabelle 4-3: Unterschiedliche Bias, welche den Entscheidungsprozess negativ beeinflussen können

Repräsentativitäts- heuristik	Verfügbarkeits- heuristik	Verankerung und Anpassung
Unempfindlichkeit gegenüber der Wahrscheinlichkeit des Ergebnisses	Verzerrungen aufgrund der Verfügbarkeit von Instanzen	Unzureichende Adaption
Unempfindlichkeit gegenüber dem Stichprobenumfang	Verzerrungen aufgrund der Güte und Vollständigkeit von Instanzen	Verzerrungen bei der Bewertung von konjunktiven und disjunktiven Ereignissen
Fehleinschätzungen des Zufalls	Verzerrungen aufgrund des Vorstellungsvermögens	Verankerung bei der Bewertung von subjektiven Wahrscheinlichkeitsverteilungen
Fehleinschätzung der Vorhersagbarkeit		
Illusion der Gültigkeit		
Fehlentwicklungen der Regression		

Defizite, welche hauptsächlich mit System 2 assoziiert werden, sind *mangelndes Expertenwissen* und *falsches Vertrauen in das System* (WANG ET AL. 2019). Mangelndes Expertenwissen führt dazu, dass trotz einer bewussten Analyse die falsche Entscheidung getroffen wird. Falsches Vertrauen in das System beschreibt die nicht gegebene Angemessenheit des Vertrauens, welches die Beziehung zwischen dem Vertrauen in das System und der Leistungsfähigkeit des Systems beschreibt.

Ist das Vertrauen in die Fähigkeiten des Systems zu groß, spricht man von übermäßigem Vertrauen (LEE & SEE 2004). Ist das Vertrauen in die Fähigkeiten des Systems zu klein, spricht man von Misstrauen in die Fähigkeiten des Systems. Sowohl das übermäßige Vertrauen als auch das Misstrauen in die Fähigkeiten des Systems resultieren in eingeschränkter Performanz des Systems. (LEE & SEE 2004) Dementsprechend ist es von Bedeutung, dem Nutzer des Systems zu ermöglichen,

die Funktionsweise eines technischen Systems nachzuvollziehen. Dies ist die Voraussetzung dafür, das Vertrauen in ebendieses zu kalibrieren.

Zusammenfassend kann festgehalten werden, dass insbesondere Personen mit Experten- bzw. Domänenwissen mit Hilfe von einfachen Heuristiken in der Lage sind, gute und schnelle Entscheidungen zu treffen. Allerdings können unterschiedliche Bias die Entscheidungen negativ beeinflussen und zu Fehlentscheidungen führen. Aus diesem Grund gilt es ein System zur Entscheidungsunterstützung zu entwickeln, welches Mitarbeiter in ihrer Entscheidungsfindung unterstützt und die Qualität derselben verbessert. Gleichzeitig gilt es die durch Bias induzierten Fehlentscheidungen zu reduzieren. Durch die verbesserte Entscheidungsfindung soll eine bessere Zielerfüllung im Rahmen der Produktionssteuerung ermöglicht werden.

Entsprechend den beiden vorgestellten Systemen zur Beschreibung der menschlichen Entscheidungsfindung aus dem Bereich der deskriptiven Entscheidungstheorie sind unterschiedliche Ansätze notwendig, um Mitarbeiter in divergierenden Entscheidungssituationen bestmöglich unterstützen zu können. Eine Einteilung in unterschiedliche Kategorien der Entscheidungsunterstützung findet im folgenden Kapitel statt.

4.3.2 Definition unterschiedlicher Kategorien der Entscheidungsunterstützung

Ausgehend von der dualen Architektur der Entscheidungspsychologie werden im Folgenden fünf Kategorien der Entscheidungsunterstützung definiert (siehe Abbildung 4-5). Die jeweiligen Kategorien zielen darauf ab, basierend auf den unterschiedlichen Systemen der Entscheidungsfindung in verschiedenen Entscheidungssituationen eine entsprechende Hilfestellung zu bieten. Die identifizierten Bias im Kontext der Entscheidungsfindung (siehe Abschnitt 4.3.1) gilt es hierbei zu berücksichtigen und abzumildern. Die fünf Kategorien wirken den entsprechenden Schwächen der jeweiligen Systeme entgegen. Die im Folgenden beschriebenen Kategorien bilden die Grundlage für das im Rahmen dieser Arbeit entwickelte lernende und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung. Hierzu erfolgt zuerst die Beschreibung der Kategorien. Anschließend werden die im vorherigen Abschnitt identifizierten Bias in den Kontext der entwickelten Kategorien gesetzt. Die Charakteristika der entwickelten Kategorien stellen die Anforderungen an die Partialsysteme dar (siehe Kapitel 5 und 6).

Kategorie	Unterstützungsart
I	Keine Unterstützung durch das System
II	Entscheidungsvorschlag ohne Zusatzinformation
III	Entscheidungsvorschlag mit Zusatzinformation
IV	Erklärung spezifischer Entscheidungsvorschläge
V	Erklärung des Modells

Abbildung 4-5: Kategorien der Entscheidungsunterstützung

Kategorie I – Keine Entscheidungsunterstützung durch das System

In Kategorie I erfolgt keine Unterstützung des Mitarbeiters. Dies kann bedeuten, dass für eine spezifische Aufgabe ein System nicht rentabel ist oder dass Mitarbeiter in diesem speziellen Fall keine Unterstützung für das zielgerichtete Erfüllen ihrer Aufgaben benötigen. Ob diese Kategorie für Mitarbeiter zur Verfügung stehen sollte, muss anwendungsfallspezifisch definiert werden.

Kategorie II – Entscheidungsvorschlag mit Zusatzinformationen

Hierbei generiert das System einen Entscheidungsvorschlag, ohne den Mitarbeitern initial zusätzliche Informationen zu dieser Entscheidung zur Verfügung zu stellen. Somit ist es den Anwendern möglich, ihre eigene Entscheidung zu überprüfen. Deckt sich diese mit der vom System vorgeschlagenen Maßnahme, so kann sie ausgeführt werden. Unterscheidet sich die vorgeschlagene Maßnahme von der vom Anwender angedachten Maßnahme, sollte eine Detailanalyse stattfinden. Hierdurch ist es den nach System 1 entscheidenden Anwendern möglich, ihr auf Erfahrungen basierendes heuristisches Handeln aufwandsarm zu überprüfen. Somit ist diese Kategorie dem System 1 zuordenbar und adressiert insbesondere das mit dem System 1 assoziierte Defizit der Heuristiken (Repräsentativitäts- und Verfügbarkeitsheuristik sowie Verankerung und Anpassung) sowie das zu System 2 zählende Defizit des mangelnden Expertenwissens (siehe Abschnitt 4.3.3).

Kategorie III – Entscheidungsvorschlag mit Zusatzinformationen

Aufbauend auf der Entscheidungsunterstützung nach Kategorie II beschreibt die Kategorie III *Entscheidungsvorschlag mit Zusatzinformationen* eine konkrete Handlungsempfehlung sowie relevante Zusatzinformationen (z. B. Informationen zu Aufträgen, Beständen und/oder Kapazitäten). Diese Kategorie adressiert Defizite sowohl von System 1 als auch von System 2. Ebenso wie Kategorie II adressiert Kategorie III insbesondere die Defizite, welche im Rahmen der schnellen, intuitiven Entscheidungsfindung von System 1 auftreten. Zusätzlich wird auch hier ein Defizit von System 2 – mangelndes Expertenwissen – adressiert.

Kategorie IV – Erklärung spezifischer Entscheidungsvorschläge

Ziel der vierten Kategorie ist es, dem Mitarbeiter eine Erklärung des systembasierten Handlungsvorschlags der Kategorie II zu liefern. Der Betrachtungsrahmen von Kategorie IV ist ein einzelner Handlungsvorschlag. Dieser kann hinsichtlich unterschiedlicher beeinflussender Faktoren analysiert werden. Somit können die eine einzelne Entscheidung des Systems zur Entscheidungsunterstützung beeinflussenden Zustände des Produktionssystems identifiziert werden. Weiterhin kann im Rahmen dieser Kategorie ebenfalls eine kontrastive Analyse erstellt werden. Diese beantwortet die Frage, wie sich der Zustand des Produktionssystems hätte ändern müssen, damit Option B und nicht Option A gewählt worden wäre. Dieses Vorgehen ähnelt stark der menschlichen Argumentationsweise bei der Beantwortung von „Was wäre wenn“-Fragen (BYRNE 2016). Für eine genauere Analyse der Entscheidungsvorschläge ist eine bewusste und kontrollierte kognitive Leistung notwendig, die dem System 2 zuordenbar ist. Die Erklärung spezifischer Entscheidungsvorschläge adressiert somit insbesondere, aber nicht ausschließlich, dem System 2 zugehörige Defizite.

Kategorie V – Erklärung der zugrunde liegenden Funktionsweise des Systemmodells

Im Rahmen der Kategorie V – *Erklärung der zugrunde liegenden Funktionsweise des Systemmodells* – wird im Gegensatz zur Kategorie IV das generelle Systemverhalten erklärt. Somit wird erläutert, welche Kriterien für die Empfehlungen von Handlungsalternativen relevant sind. Für die Analyse des generellen Systemverhaltens ist ebenso wie bei der vorherigen Kategorie eine bewusste und kontrollierte kognitive Leistung notwendig. Demzufolge kann diese Kategorie primär mit dem System 2 assoziiert werden.

4.3.3 Kategorien der Entscheidungsunterstützung im Kontext der dualen Architektur der Entscheidungspsychologie

Im Folgenden wird der Zusammenhang zwischen den definierten Kategorien der Entscheidungsunterstützung sowie den adressierten Defiziten der dualen Architektur der Entscheidungspsychologie beschrieben (siehe Abbildung 4-6). Dabei steht die Mitigation der in Abschnitt 4.3.1 beschriebenen Bias durch die Kategorien der Entscheidungsunterstützung (siehe Abschnitt 4.3.2) im Fokus.

Die mit den Repräsentativitätsheuristiken assoziierten Bias werden insbesondere durch Anwendung der Kategorien II und III des Systems zur Entscheidungsunterstützung verringert. Daraus abgeleitet können an die Realisierung dieser Kategorien die Anforderungen gestellt werden, dass

- vorherige Wahrscheinlichkeiten,
- die Auftretenshäufigkeit von Ereignissen und
- die objektive Wahrscheinlichkeit für die spezifische Entscheidung

berücksichtigt werden. Ebenso gilt es die Bias, welche durch das Entscheiden mit Hilfe einer Verfügbarkeitsheuristik entstehen, mit den Kategorien II und III des Systems zur Entscheidungsunterstützung abzumildern. Deshalb muss das System in der Lage sein,

- Entscheidern eine einfache Zugänglichkeit zu Informationen zu ermöglichen,
- ein benutzerrollenindividuelles Informationsangebot zu ermöglichen und
- einen möglichst großen Lösungsraum zu durchsuchen.

Somit ist es möglich, dass die Anforderungen an die kognitive Leistung des Entscheiders für das Verwenden des Systems zur Entscheidungsunterstützung möglichst gering ist und das System somit häufiger eingesetzt wird.

Die Bias der Entscheidungsheuristik *Verankerung und Anpassung* gilt es primär ebenfalls mit den Kategorien II und III der Entscheidungsunterstützung zu reduzieren. In diesem Fall sind Fehlentscheidungen hauptsächlich durch einen falschen Ausgangspunkt des Entscheidungsfindungsprozesses geprägt. Da systembedingt bereits eine tendenziell gute Lösung des Entscheidungsproblems vorgeschlagen wird, wird der Ausgangspunkt für Überlegungen zu einer potenziellen Überplanung durch Mitarbeiter mit Hilfe des Systems gesetzt.

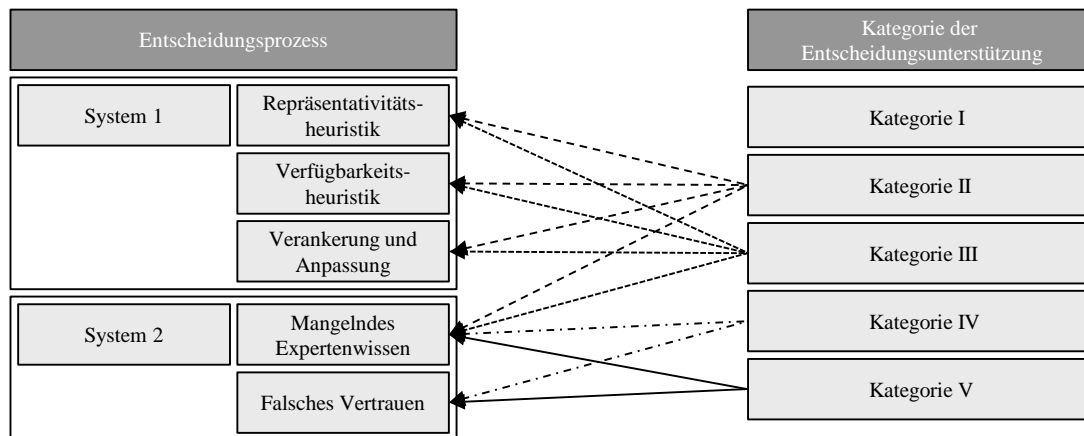


Abbildung 4-6: Zusammenhang zwischen den definierten Kategorien der Entscheidungsunterstützung und den adressierten Defiziten der dualen Architektur der Entscheidungspsychologie

Ein Grund für Fehlentscheidungen kann ebenso mangelndes (Experten-)Wissen sein. Durch die Unterstützung in Entscheidungssituationen in Form einer Handlungsempfehlung wird dieser Bias sowohl von den Kategorien II und III als auch von den Kategorien IV und V adressiert.

Falsches Vertrauen in die Fähigkeiten des Systems zur Entscheidungsunterstützung kann ebenfalls zu Fehlentscheidungen führen. Hierbei gilt es, zwischen übermäßigem und mangelndem Vertrauen zu differenzieren. Übermäßiges Vertrauen bedeutet, dass die Fähigkeiten des Systems überschätzt werden und daraus resultierend Fehlanwendungen auftreten. Aus mangelndem Vertrauen in die Fähigkeiten des Systems, kann eine seltenere Anwendung desselben resultieren. (LEE & SEE 2004) Durch die Kategorien IV und V der Entscheidungsunterstützung wird dieser Bias adressiert, da durch die Erklärung spezifischer Entscheidungsvorschläge bzw. des Modells die Funktionsweise und die Limitationen besser abgeschätzt werden können.

4.4 Benutzerrollenspezifisches Referenzmodell

Das benutzerrollenspezifische Referenzmodell besteht aus den identifizierten Benutzerrollen, dem Maßnahmenreferenzkatalog sowie den Kategorien der Entscheidungsunterstützung (siehe Abbildung 4-7). Diese drei Dimensionen gilt es zur Erstellung des benutzerrollenspezifischen Informationsmodells unternehmensspezifisch anzupassen (siehe Abschnitt 4.5). Mit Hilfe des benutzerrollenspezifischen Referenzmodells wird die Grundlage für die Erstellung der Partialsysteme des ler-

nenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung geschaffen. Die anwendungsfallsspezifische Anpassung des Referenzmodells erfolgt im nächsten Abschnitt.

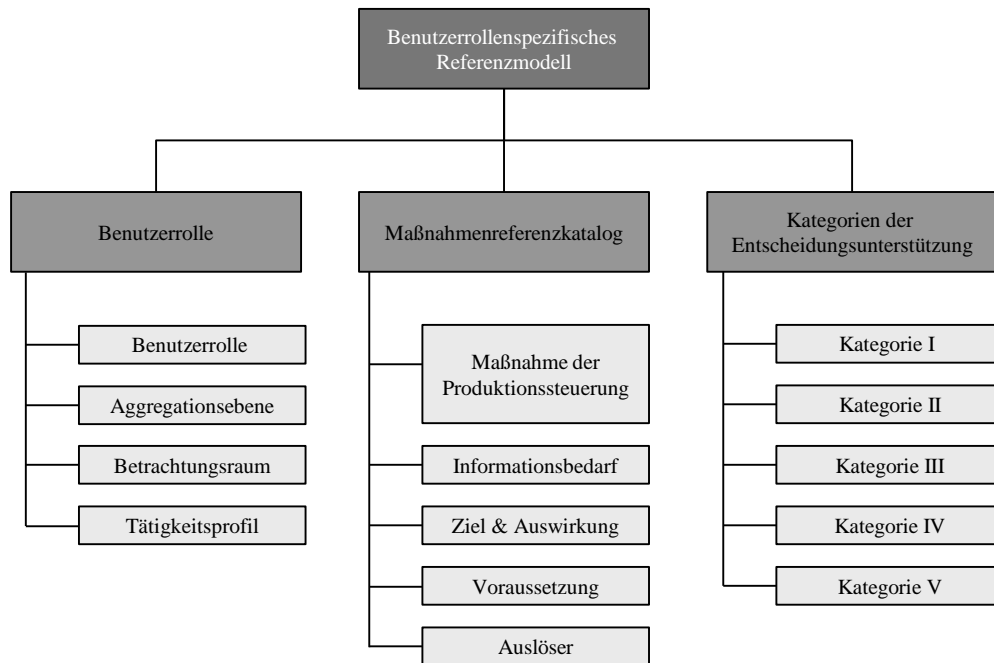


Abbildung 4-7: Überblick über das benutzerrollenspezifische Referenzmodell

4.5 Vorgehen zur unternehmensspezifischen Anpassung des Informationsmodells

Zur Generierung eines unternehmens- und benutzerrollenspezifischen Informationsmodells gilt es, basierend auf dem entwickelten Referenzmodell, unterschiedliche Schritte durchzuführen (siehe Abbildung 4-8). Ziel ist es hierbei, die Charakteristika von Unternehmen zu berücksichtigen und somit die für die Produktionssteuerung relevanten Benutzerrollen eines Unternehmens, die Maßnahmen der Produktionssteuerung sowie den individuellen Unterstützungsbedarf der Benutzerrollen zu definieren.

Im ersten Schritt werden die für die Produktionssteuerung relevanten Benutzerrollen beschrieben. Ausgehend von den generisch charakterisierten Benutzerrollen sowie den im Unternehmen agierenden Benutzern (siehe Abschnitt 4.2.1) erfolgt

eine systematische Ableitung und Charakterisierung der Benutzerrollen. Die Anpassung der Benutzerrollen findet somit in Abhängigkeit von den im Produktionssystem vorhandenen Benutzern statt. Die identifizierten Benutzer werden anhand charakteristischer Merkmale beschrieben. Dies ermöglicht die Zuordnung der Benutzerrollen zu spezifischen Aggregationsebenen des Produktionssystems (z. B. Arbeitsstation) sowie die Identifikation von Verbindungen bzw. Abhängigkeiten innerhalb des Produktionssystems. Somit können bspw. hierarchische Strukturen innerhalb der Fabrik identifiziert und beschrieben werden.

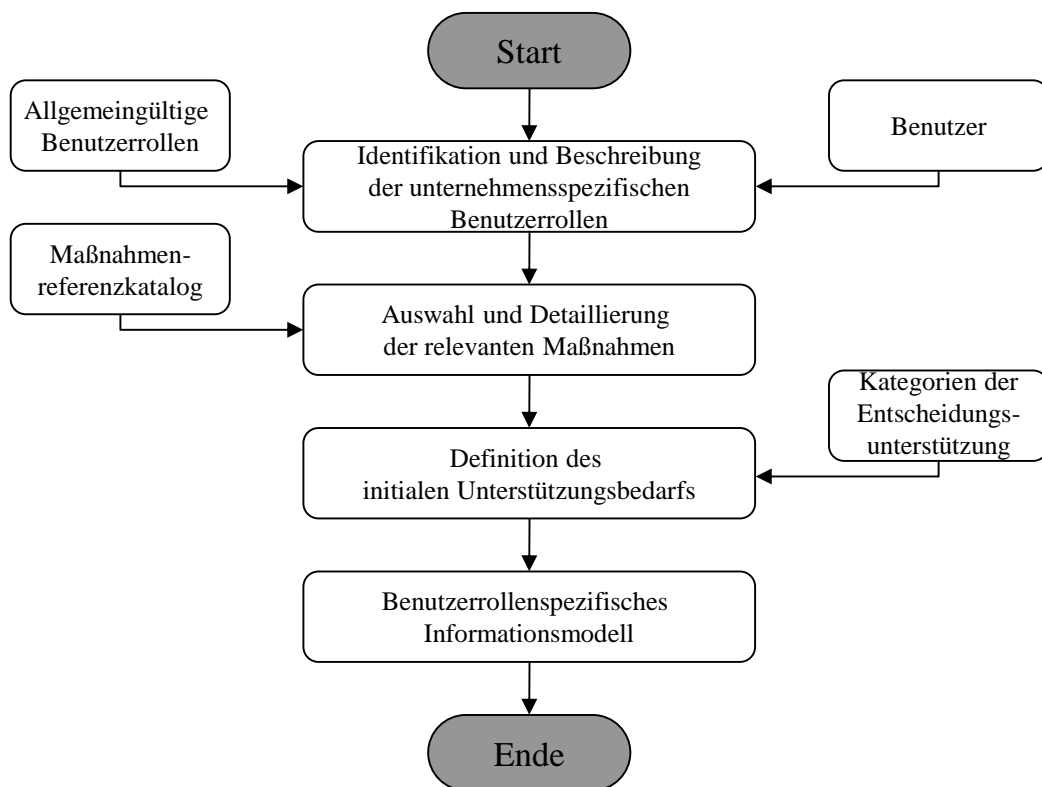


Abbildung 4-8: Ablauf der unternehmensspezifischen Anpassung des entwickelten Referenzmodells

Im zweiten Schritt erfolgt das Schärfen des Rollenverständnisses der identifizierten Benutzerrollen. Ausgehend vom in Abschnitt 4.2.2 definierten allgemeingültigen Maßnahmenreferenzkatalog werden die in Abhängigkeit von spezifischen Benutzerrollen möglichen Maßnahmen der Produktionssteuerung abgeleitet. Somit ist es möglich, für jede Benutzerrolle detailliert festzulegen, welche Maßnahmen der Produktionssteuerung ergriffen werden können.

Anschließend erfolgt im Rahmen des dritten Schritts die Einordnung der Benutzerrollen in die entwickelten Kategorien der Entscheidungsunterstützung (siehe Abschnitt 4.3.2). Ziel ist es, in Abstimmung mit den betroffenen Benutzern eine

initiale Einordnung der jeweiligen Benutzerrolle durchzuführen. Zu betonen ist, dass es sich hierbei ausschließlich um eine *initiale* Einordnung handelt. Prinzipiell gilt es, den Grad der Entscheidungsunterstützung auch im produktiven Betrieb ändern zu können und somit ein adaptives System zur Entscheidungsunterstützung zu realisieren.

Das Resultat dieser drei Schritte ist ein benutzerrollenspezifisches Informationsmodell. Innerhalb von definierten Systemgrenzen der Produktionssteuerung beschreibt dieses strukturiert die relevanten Benutzerrollen, deren mögliche Maßnahmen sowie die initiale Einordnung in die Kategorien der Entscheidungsunterstützung.

4.6 Fazit

In diesem Kapitel wurde beschrieben, wie die strukturierte Erfassung unterschiedlicher Informationen zur Unterstützung in Entscheidungssituationen erfolgen kann. Hierfür wurden im ersten Schritt die unterschiedlichen beteiligten Benutzerrollen identifiziert, welche im Rahmen der Produktionssteuerung in den Produktionsablauf eingreifen können. Anschließend wurde ein Maßnahmenreferenzkatalog erstellt. Dieser soll als Ausgangspunkt für die Identifikation der unterschiedlichen Maßnahmen dienen, welche im betrachteten Produktionssystem initiiert werden können. Anschließend wurden, basierend auf dem menschlichen Entscheidungsverhalten, unterschiedliche Unterstützungskategorien definiert, welche in Entscheidungssituationen der Produktionssteuerung Defizite des menschlichen Entscheidungsprozesses abmildern. Zuletzt wurde beschrieben, wie diese Bestandteile durch eine unternehmensspezifische Adaption mit einem benutzerspezifischen Informationsmodell verknüpft werden können. Durch die Anwendung des Vorgehens und die damit einhergehende Adaption der drei Bestandteile kann ein unternehmensspezifisches Informationsmodell entwickelt werden. Dieses bildet die Grundlage für die systembasierte Unterstützung in Entscheidungssituationen der Produktionssteuerung.

5 Lernende benutzerrollenspezifische Produktionssteuerung

5.1 Allgemeines

Das vorliegende Kapitel erläutert, ausgehend von den in Kapitel 3 definierten Systemanforderungen sowie dem entwickelten benutzerrollenspezifischen Informationsmodell (siehe Abschnitt 4.5), den Aufbau des Agentensystems zur Produktionssteuerung. Das Ziel ist die Realisierung der Entscheidungsunterstützung von Mitarbeitern in Entscheidungssituationen. Im Rahmen dieses Kapitels stehen die Auswahl und die Bewertung von Maßnahmen entsprechend der in Abschnitt 4.3.2 definierten Kategorien II und III der Entscheidungsunterstützung im Fokus. Mit Hilfe des Agentensystems werden unterschiedliche Benutzer und deren Handlungsspielräume repräsentiert. Dadurch ist es möglich, den Systemanwendern in Abhängigkeit vom Zustand der Produktion und des Unterstützungsbedarfs die bestmögliche Maßnahme vorzuschlagen.

Die notwendigen Bestandteile für die Realisierung eines lernenden agentenbasierten Systems sind in Abbildung 5-1 dargestellt. Dabei handelt es sich um das *Produktionssystem*, das *Agentensystem* sowie das eingesetzte *Lernverfahren*. In Abschnitt 5.2 wird zunächst die Modellierung des Produktionssystems detailliert dar-

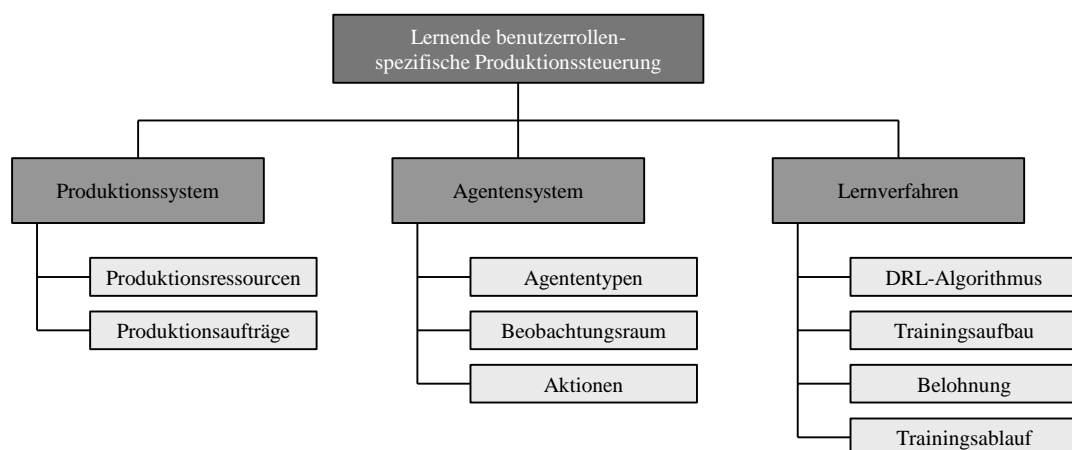


Abbildung 5-1: Bestandteile des Agentensystems zur Realisierung der lernenden benutzerrollenspezifischen Entscheidungsunterstützung im Kontext der Produktionssteuerung

gestellt. Anschließend erfolgt in Abschnitt 5.3 die Beschreibung des Agentensystems unter Berücksichtigung unterschiedlicher Agententypen, des Aktionsraums sowie des Beobachtungsraums. Damit die Agenten in Abhängigkeit vom aktuellen Zustand des Produktionssystems geeignete Aktionen auswählen können, wird in Abschnitt 5.4 der Ablauf des auf tiefem Lernen basierenden RL-Ansatzes erörtert. Abschließend erfolgt in Abschnitt 5.5 eine Beschreibung der notwendigen Schritte zur unternehmensspezifischen Anpassung.

5.2 Modellierung des Produktionssystems

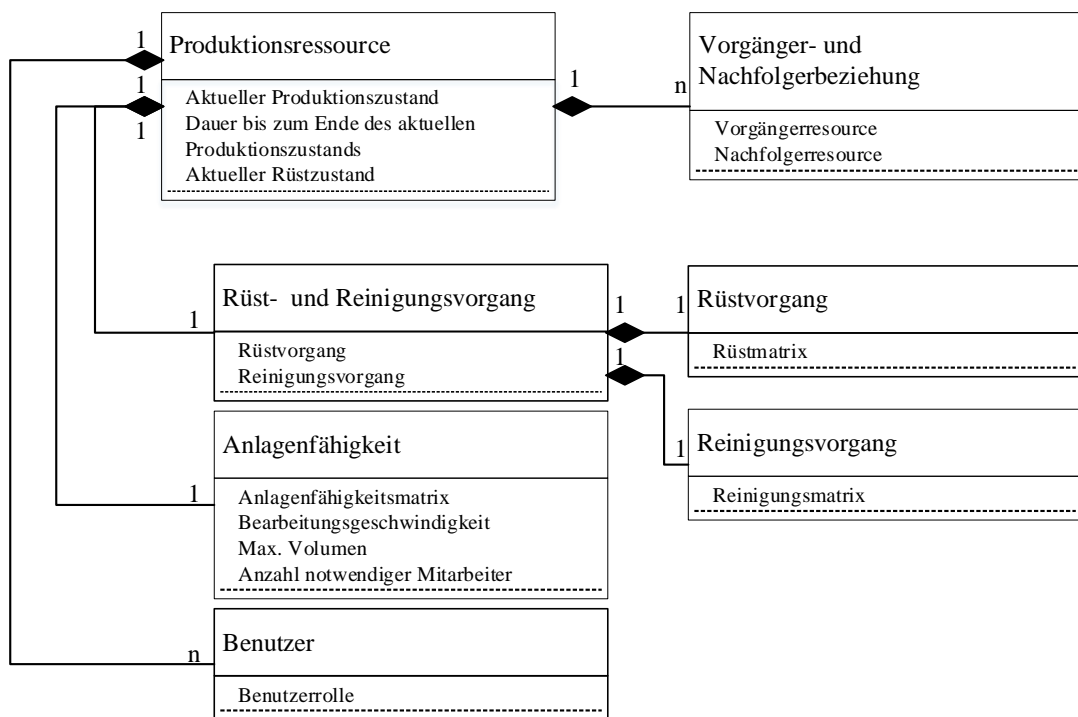
Durch die Modellierung des Produktionssystems werden die relevanten Daten strukturiert erfasst und die erforderliche Transparenz zum zielgerichteten Ausführen der Aufgaben der Produktionssteuerung geschaffen. Charakteristisch für ein Produktionssystem ist die Transformation eines Inputs (z. B. Werkstoffe, Informationen, Teile, Energie etc.) durch eine definierte Arbeitsaufgabe zu einem Output (z. B. Produkte, Informationen, Energie etc.) (HEINEN ET AL. 2008). Für die Herstellung der Güter interagieren die Elemente Mensch und Betriebsmittel miteinander (SCHMIDTKE 1976, REFA 1984). Im Rahmen dieser Arbeit wird ein modularer Aufbau des Produktionssystems basierend auf einzelnen Produktionsressourcen gewählt. Somit kann eine einfache Adaption an sich verändernde Randbedingungen in der Produktion (z. B. Erweiterung des Anlagenparks) realisiert werden. Im Folgenden wird auf die Modellierung der Produktionsressourcen und Produktionsaufträge eingegangen. Dies bildet die Voraussetzung für eine strukturierte Erfassung der relevanten Daten.

Modellierung einer Produktionsressource

Die Produktionsressource beinhaltet Daten über ihren aktuellen Zustand (z. B. produzierend, wartend), den durch die Produktionsressource produzierten Auftrag, die verbleibende Dauer bis zum Ende des aktuellen Zustands sowie den aktuellen Rüstzustand (siehe Abbildung 5-2). Zusätzlich können diese Parameter allerdings um spezifische Faktoren wie z. B. Energieverbrauch (RÖSCH 2021) oder Risikopräferenz (KLÖBER-KOCH 2021) ergänzt werden. Im Rahmen dieser Arbeit stehen diese Erweiterungen allerdings nicht im Fokus, weshalb sie im Folgenden nicht detailliert betrachtet werden.

Die Verknüpfungen einer Produktionsressource mit einer oder mehreren weiteren Produktionsressourcen – der Materialfluss – werden durch die eindeutige Definition der Vorgänger- und Nachfolgerbeziehung bestimmt. Somit können die im realen Produktionssystem bestehenden Verbindungen abgebildet werden.

Der Rüstvorgang kann mit Hilfe einer Rüstmatrix beschrieben werden. Die Rüstdauer hängt dabei vom Vorgängerartikel sowie dem zu fertigenden Produkt ab und kann durch die entsprechende Spalten-Zeilen-Kombination direkt der Rüstmatrix entnommen werden (ERLACH 2020). Ergänzend zur Rüstmatrix beschreibt die Reinigungsmatrix die notwendige Dauer für eventuelle Reinigungsprozesse, welche bei einem Produktwechsel notwendig sind. Die notwendige Zeit für einen Reinigungsprozess ist ebenso vom Vorgängerartikel wie auch vom zu fertigenden Produkt abhängig.



Legende:

 : Klasse — : Assoziation 0, ...,n: Multiplizität einer Assoziation ◆ : Aggregation

Abbildung 5-2: Unified Modeling Language(UML)-Notation der Produktionsressource (i. A. an OSTGATHE 2012)

Die Anlagenfähigkeit beschreibt, welche Produkte unter Berücksichtigung welcher Randbedingungen gefertigt werden können. Dafür werden die Anlagenfähigkeitsmatrix, die Bearbeitungsgeschwindigkeit in Abhängigkeit vom Auftragstyp, die maximale Produktionskapazität sowie die Anzahl der notwendigen Mitarbeiter verwendet. Hierbei beschreibt die Anlagenfähigkeitsmatrix, welche Produkte auf der jeweiligen Anlage gefertigt werden können. Durch die maximale Produktionskapazität wird die Quantität beschrieben, welche eine Anlage ohne notwendige Zwischenschritte (z. B. Reinigung, Instandhaltung) produzieren kann. Sowohl die Bearbeitungsgeschwindigkeit als auch die Anzahl notwendiger Mitarbeiter kann von der spezifischen Anlage sowie den zu fertigenden Produkten abhängen.

Modellierung des Produktionsauftrags

Im Folgenden wird näher auf die Modellierung des Produktionsauftrags eingegangen (siehe Abbildung 5-3). Diese ist für die Produktionssteuerung von essenzieller Bedeutung, da sich aus den Charakteristika eines Auftrags die Randbedingungen während der Produktion (z. B. notwendige Rüst- und Reinigungszeiten) ergeben.

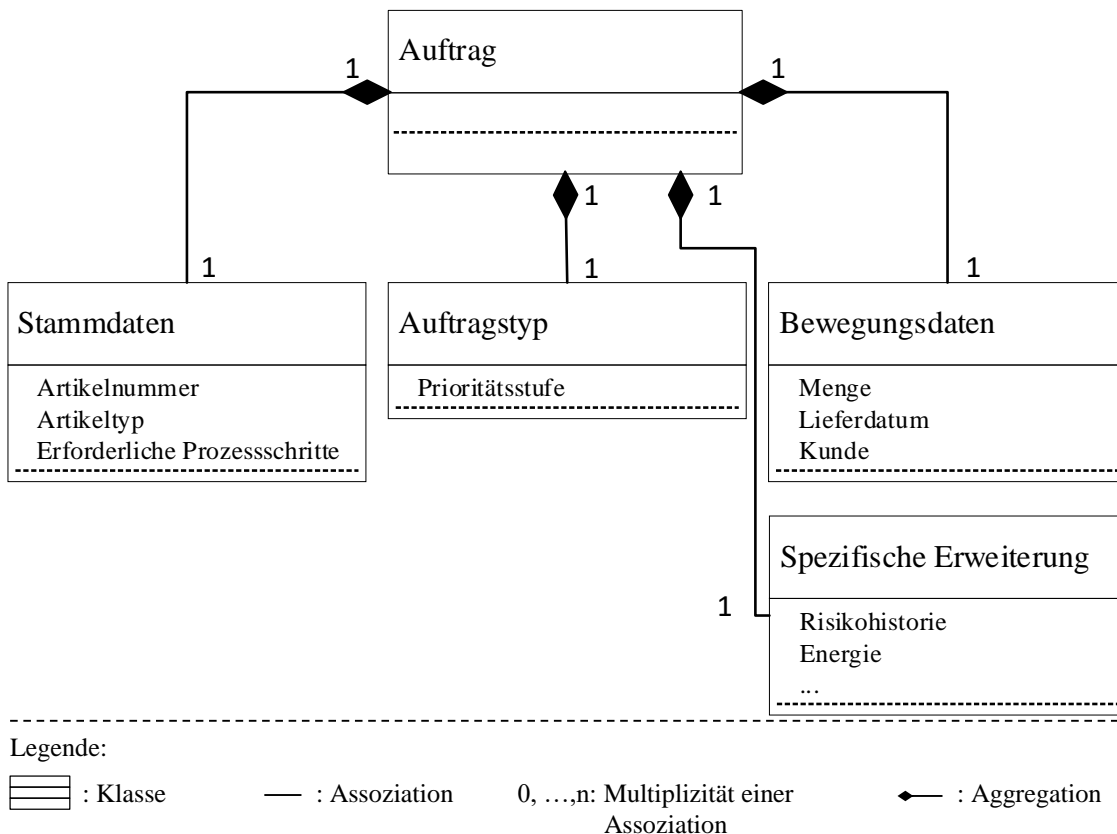


Abbildung 5-3: UML-Notation des Auftragsmodells (i. A. an LOOS 1999, OSTGATHE 2012, KLÖBER-KOCH 2021, RÖSCH 2021)

Damit die Varianz (z. B. unterschiedliche Mengen, unterschiedliche Dringlichkeiten) der Aufträge berücksichtigt werden kann, erfolgt im Rahmen dieser Arbeit die Modellierung der Aufträge mit Hilfe der Stamm- und Bewegungsdaten nach LOOS (1999).

In den *Stammdaten* sind vornehmlich Daten hinterlegt, welche durch eine geringe Veränderungshäufigkeit charakterisiert sind. Dies sind z. B. die Artikelnummer, der Artikeltyp und erforderliche Prozessschritte. *Bewegungsdaten* sind hingegen durch eine befristete Lebensdauer gekennzeichnet. Diese Daten werden bei der Erstellung eines neuen Auftrags generiert. In Verbindung mit den in den Produktionsressourcen hinterlegten Daten können die auftragsspezifischen Zeiten (z. B. Bearbeitungszeit) an den jeweiligen Produktionsressourcen berechnet werden. Indem die Zeiten für jeden Auftrag individuell berechnet werden, können unterschiedliche Anlagenfähigkeiten (z. B. Bearbeitungsgeschwindigkeit) berücksichtigt werden. Die Möglichkeit, spezifische Bearbeitungszeiten zu berechnen, ist für die exakte Abbildung des Produktionsablaufs relevant. Häufig werden zur Berechnung allerdings Mittelwerte verwendet, was den Ansprüchen an ein zeitgemäßes PPS-System nicht gerecht wird (AUERBACH ET AL. 2011).

Der Auftragsstyp beschreibt unterschiedliche Prioritätsstufen des Auftrags. Beispiele für solche Prioritätsstufen sind Eilaufträge und Normalaufträge. Dadurch wird die Bedeutung der Aufträge für das Unternehmen zusätzlich betont. Eilaufträge stellen für den Produktionsablauf eine Herausforderung dar, da sie u. a. zu höheren Rüstkosten, Verzugskosten für Normalaufträge sowie höheren Distributivkosten führen (LÖDDING 2016).

Die Modellierung des Produktionssystems ermöglicht es, die für das System zur Entscheidungsunterstützung notwendigen Informationen strukturiert zu erfassen, und generiert dadurch ebenfalls Transparenz über den Ist-Zustand der Produktion. Gleichzeitig bietet sie die Grundlage für den Aufbau bzw. die Entwicklung des Simulationsmodells, welches für das Training des Agentensystems notwendig ist.

5.3 Agentensystem

Entsprechend der VDI/VDE 2653-1 ist ein Agent durch Interaktionen mit seiner Umgebung gekennzeichnet, um definierte Aufgabenstellungen zu lösen. In einem Agentensystem interagieren mehrere Agenten miteinander, mit dem Ziel, spezifische Aufgabenstellungen zu lösen. Charakteristisch für das Agentensystem sind u. a. die Rollen der Agenten. Durch diese ist es möglich, die Aufgabe der Agenten

zu definieren. (VDI/VDE 2653-2) Im Rahmen dieser Arbeit werden die Rollen der Agenten anhand von Agententypen, teilweise auch als Entwurfsmuster für Agenten bzw. Agentenmuster bezeichnet (VDI/VDE 2653-4), beschrieben. In Abschnitt 5.3.1 wird die Ableitung unterschiedlicher Agententypen dargelegt. Anschließend erfolgt die Modellierung des Beobachtungsraums (siehe Abschnitt 5.3.2), welcher einen Ausschnitt des Produktionssystems beschreibt. Dieser Ausschnitt kann je nach Agent variieren und muss dementsprechend nicht immer derselbe sein. Basierend auf dem Zustand dieses Ausschnitts wählt der Agent bzw. wählen die Agenten die am besten geeignete(n) Aktion (Aktionen) aus. Welche Aktionen ausgewählt werden können, wird in Abschnitt 5.3.3 detailliert beschrieben.

5.3.1 Benutzerzentrierte Entwurfsmuster für Agenten

Entsprechend der in Kapitel 4 vorgestellten Systemübersicht ist das Ziel des Agentensystems die Unterstützung von Mitarbeitern bei Entscheidungen, welche es im Rahmen der Produktionssteuerung zu treffen gilt. Im Rahmen dieser Arbeit dienen die in Kapitel 5 identifizierten Benutzerrollen als Basis für die einzelnen Agententypen. Dabei werden unterschiedliche Entwurfsmuster für Agenten zur Erfüllung der Aufgaben der Produktionssteuerung realisiert. Ziel ist es, ein methodisches Vorgehen für die Erstellung des Agentensystems zu entwickeln sowie die grundsätzlichen Eigenschaften eines Agenten zu beschreiben. Durch die Abbildung der Benutzerrollen sowie der zugehörigen Aufgaben kann ein System zur Entscheidungsunterstützung geschaffen werden, welches eine benutzerrollenspezifische Bereitstellung von relevanten Informationen sowie benutzerrollenspezifische Handlungsalternativen ermöglicht. Eine benutzerrollenorientierte Informationsbereitstellung unter Berücksichtigung spezifischer Aufgaben gewährleistet eine hohe Qualität und Effektivität beim Erfüllen der Aufgaben (KLETTI 2015c). Die hierfür notwendigen Informationen können sich in ihrer Art deutlich unterscheiden.

Zur Bewältigung komplexer Aufgaben ist das Aufteilen derselben ein erfolgversprechender Ansatz. Hierdurch kann die Komplexität der Teilaufgaben deutlich reduziert und somit potenziell ein besseres Systemverhalten erzielt werden (VOGEL-HEUSER ET AL. 2015).

In Abbildung 5-4 sind Kriterien aufgeführt, anhand derer unterschiedliche Entwurfsmuster für Agenten charakterisiert werden können. Dies ermöglicht eine strukturierte Beschreibung der im Rahmen des Systems zur Entscheidungsunterstützung einzusetzenden Agenten. Die von VOGEL-HEUSER ET AL. (2018), ECKERT ET AL. (2012) und der VDI/VDE 2653-4 definierten Charakteristika werden im

Rahmen dieser Arbeit vier Kategorien – *Allgemeine Informationen*, *Anwendungsfall*, *(Lern-)Verhalten* und *Sonstiges* – zugeordnet. Der Fokus liegt im Folgenden auf den für diese Arbeit relevanten Charakteristika. Für eine vollumfängliche Charakterisierung sei auf VOGEL-HEUSER ET AL. (2018), ECKERT ET AL. (2012) und VDI/VDE 2653-4 verwiesen.

Die Kategorie *Allgemeine Informationen* enthält die grundlegenden Informationen eines Agentenentwurfsmusters. Hierzu zählen der Name, die Benutzerrolle, die Musterkategorie, der Mustertyp sowie eine allgemeine Beschreibung. Der Name dient zur Identifizierung des Agenten (VDI/VDE 2653-4). Mit der Benutzerrolle wird definiert, welche Benutzerrolle als Grundlage für einen spezifischen Agenten dient. Die Musterkategorie beschreibt die Eigenschaften (z. B. Verbesserung der Auftragsfreigabe), welche durch den Einsatz des Agenten verbessert werden können (VOGEL-HEUSER ET AL. 2018). Der Mustertyp enthält Informationen über die Aufgabe, welche der Agent zu lösen hat (z. B. Bildung einer Auftragsreihenfolge). Hierbei wird die Technologie, welche zur Lösung der Aufgabe verwendet werden kann, nicht berücksichtigt (VOGEL-HEUSER ET AL. 2018).

Innerhalb der Kategorie *Anwendungsfall* werden die unternehmensspezifischen, anwendungsfallspezifischen Informationen erfasst. Durch die Beschreibung des Anwendungsbereichs werden die Systemgrenzen für den Agenten bzw. die Agenten gesetzt. Die Agentensystemarchitektur beschreibt den Aufbau und das Verhal-

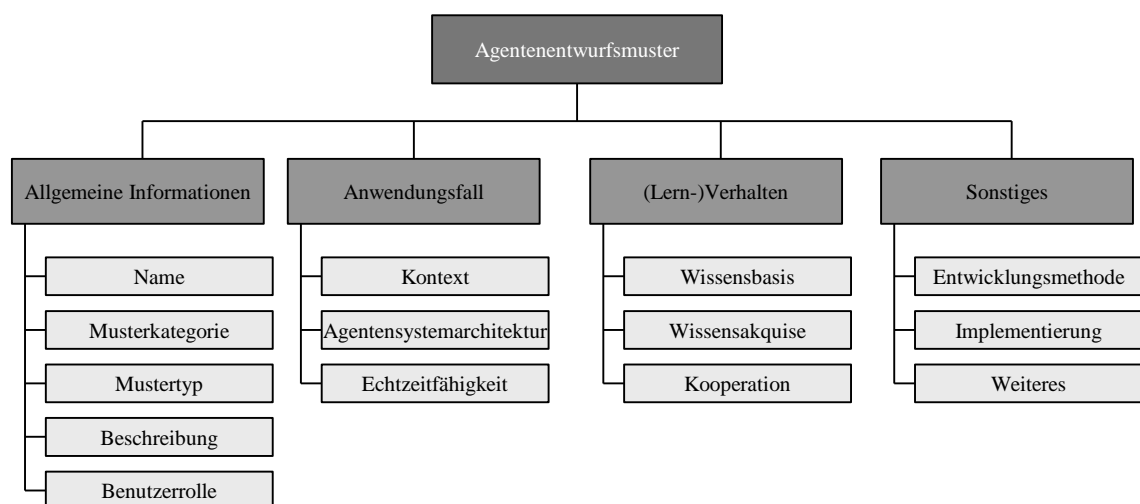


Abbildung 5-4: Merkmale zur Charakterisierung unterschiedlicher Agentenentwurfsmuster (i. A. an VOGEL-HEUSER ET AL. 2018, ECKERT ET AL. 2012 und VDI/VDE 2653-4)

ten der Agenten (z. B. reaktiv). Mit Hilfe der Subkategorie *Echtzeitfähigkeit* werden die Anforderungen an die Reaktionszeit beschrieben. (VOGEL-HEUSER ET AL. 2018)

Das (*Lern-*)*Verhalten* umfasst die Informationen zur Wissensbasis, Wissensakquise und Kooperation der Agenten. Die Wissensbasis beschreibt die Art und Weise, wie das Wissen für die Entscheidungsauswahl der Agenten hinterlegt ist (z. B. in Form von Regeln oder Modellen). Das Lernverhalten der Agenten wird durch die Wissensakquisition beschrieben. (VOGEL-HEUSER ET AL. 2018, VDI/VDE 2653-4)

Informationen zur Entwicklungsmethode und Implementierung werden in der Kategorie *Sonstiges* erfasst. Durch die Subkategorie *Implementierung* erfolgt die Beschreibung der Art und Weise, wie die Agenten implementiert sind (VOGEL-HEUSER ET AL. 2018). Zusätzlich können weitere Informationen ergänzt werden.

Im Folgenden wird beschrieben, wie die einzelnen Agenten, welche mit Hilfe der vorgestellten Charakteristika beschrieben werden können, in einem System zur Entscheidungsunterstützung interagieren können.

Aufbau des Agentensystems

In einem Agentensystem interagieren die Agenten miteinander, um ein gemeinsames Ziel zu erreichen. Dabei unterscheiden sich die einzelnen Aufgaben der Agenten voneinander. Da im Rahmen dieser Arbeit die Mitarbeiter eine besondere Berücksichtigung finden, wird der Aufbau des Agentensystems vom organisatorischem Aufbau im Unternehmen abgeleitet. Dieser Ansatz wird u. a. von MONOSTORI ET AL. (2006) vorgeschlagen. Als Ausgangspunkt können die in Abschnitt 4.2.1 und 4.5 identifizierten Benutzerrollen inklusive der Zuordnung zur entsprechenden Unternehmensebene verwendet werden.

Abbildung 5-5 beschreibt schematisch den Aufbau eines hierarchischen Agentensystems. Darin sind beispielhaft drei unterschiedliche Agententypen – Produktionssteuerer-, Meister- und Anlagenbedieneragent – enthalten. Jeder der Agenten hat, analog zur korrespondierenden Benutzerrolle, einen eigenen Beobachtungs- und Aktionsraum im Kontext der Produktionssteuerung. Trotz der unterschiedlichen Gestaltung interagieren die Agenten direkt oder indirekt miteinander.

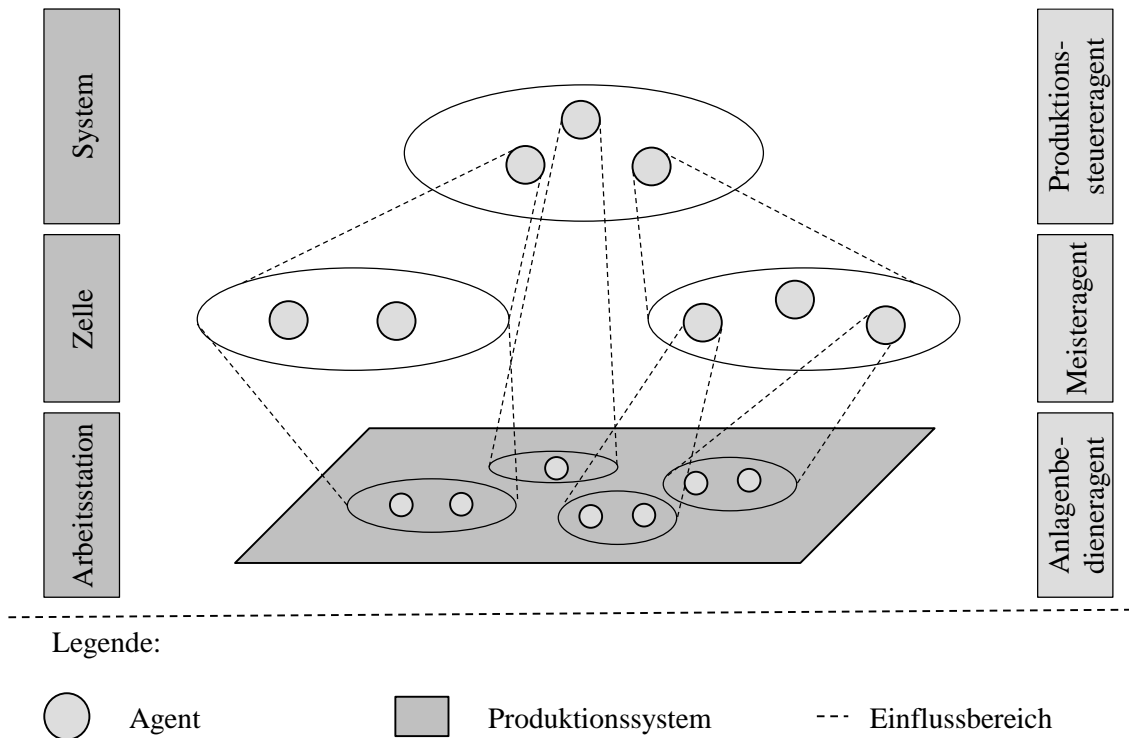


Abbildung 5-5: Schematischer Aufbau eines Agentensystems in Abhängigkeit von den unterschiedlichen Aggregationsebenen eines Produktionssystems (i. A. an JENNINGS 2001, MONOSTORI ET AL. 2006)

5.3.2 Zustandsraum

Prinzipiell hat jeder Agent einen eigenen Zustandsraum, welcher Informationen über den aktuellen Zustand des Produktionssystems enthält. Für Agentensysteme ist der Zustands- und Aktionsraum von essenzieller Bedeutung. Durch den Zustandsraum wird bestimmt, welche Informationen dem Agenten als Eingangsvektor zur Verfügung stehen und wie folglich die Umgebung wahrgenommen wird. Hierdurch wird die bestmögliche Auswahl von Aktionen in Abhängigkeit vom Systemzustand ermöglicht.

Damit die Agenten in Übereinstimmung mit der Produktionssituation die bestmögliche Maßnahme auswählen können, ist es notwendig, sowohl Informationen über den Wert relevanter Parameter der Produktionsressourcen als auch Informationen zu den Aufträgen in geeigneter Form zur Verfügung zu stellen. Es gibt prinzipiell zwei Möglichkeiten, wie dies erfolgen kann. Einerseits können die Aufträge direkt im Beobachtungsraum der Agenten abgebildet werden (*Auftragssicht*). Andererseits können Aufträge Kategorien bzw. Klassen von Aufträgen zugeordnet werden (*Klassensicht*).

Bei der *Auftragssicht* werden die einzelnen Aufträge dezidiert beschrieben. Hierzu wird für jeden Agenten eine maximale Anzahl an Aufträgen festgelegt, welche im Beobachtungsraum des Agenten repräsentiert werden (THEUMER ET AL. 2022). Wird die Strategie der einzelnen Agenten durch ein KNN repräsentiert, so wird der Beobachtungsraum umgesetzt, in dem jeder Auftrag durch ein Neuron in der Eingabeschicht des KNN repräsentiert wird. Variiert die Anzahl der Aufträge, so werden die nicht besetzten Neuronen durch den Wert 0 aufgefüllt. Dies wird auch als *Padding* bezeichnet. Sind im Eingangspuffer eines Agenten wenige Aufträge vorhanden, so ist die Anzahl der Einträge des Eingangsvektors, welche den Wert 0 annehmen, hoch. Zusätzlich ist die Position der Aufträge im Eingangsvektor bei der Auftragssicht nicht vordefiniert. Bei einer Veränderung des Produktionssystems (z. B. Produktionsstart eines Auftrags) werden die im Eingangsvektor enthaltenen Informationen aktualisiert. Dies kann ebenfalls eine Auswirkung auf die Reihenfolge der mit den Aufträgen korrespondierenden Einträge des Eingabevektors haben. Prinzipiell kann die Aktualisierung einerseits Informationen zu einem neuen Auftrag oder andererseits, falls keine weiteren Aufträge zur Verfügung stehen, das Auffüllen mit dem Wert 0 beinhalten. Für den Lernprozess der Strategie eines Agenten bedeutet dies eine zusätzliche Komplexität, welche sich negativ auf die Dauer und die Qualität des Lernprozesses auswirken kann. Innerhalb der Auftragssicht kann gemäß RÖSCH (2021) zudem eine Modellierung der Aufträge anhand charakteristischer Parameter des Auftrags (z. B. Bearbeitungsdauer) oder des Auftragsstyps erfolgen.

Dagegen erfolgt bei der *Klassensicht* eine Strukturierung des Beobachtungsraums, indem die unterschiedlichen Aufträge Klassen zugeordnet werden. Diese Zuordnung kann basierend auf charakteristischen Merkmalen (z. B. Produktkategorie) erfolgen, welche Einfluss bspw. auf die Rüstzeit haben. Ein Wechsel außerhalb der Produktkategorie könnte z. B. längere Rüstvorgänge bedingen als ein Wechsel innerhalb der gleichen Produktkategorie. Die Definition der unterschiedlichen Klassen kann entweder durch Experten oder den Einsatz statistischer Verfahren (z. B. Hauptkomponentenanalyse, k-Means-Algorithmus) erfolgen.

Der Tabelle 5-1 kann die Charakterisierung der beiden Varianten entnommen werden. Welche Sicht am besten geeignet ist, hängt einerseits von den Randbedingungen des Produktionssystems (z. B. Auftragsanzahl, Maschinenanzahl) ab, andererseits von der zu bevorzugenden Sicht des spezifischen Agenten und dessen Aufgabe. Basierend auf durchgeführten Simulationsstudien hat sich gezeigt, dass insbesondere bei einer hohen Anzahl unterschiedlicher Artikel das Verwenden der

Tabelle 5-1: Charakterisierung der Auftrags- und Klassensicht

Auftragssicht	Klassensicht
<ul style="list-style-type: none"> ▪ Beobachtungsraum nimmt proportional zur Anzahl der Aufträge zu ▪ Vollständige Informationsmodellierung möglich ▪ Padding notwendig, wenn die Anzahl der Aufträge unterhalb eines definierten Grenzwerts liegt 	<ul style="list-style-type: none"> ▪ Beobachtungsraum nimmt proportional zur Anzahl der Klassen zu ▪ Informationsverlust durch vereinfachte Modellierung ▪ Kohärente Merkmale (unabhängig von den sich im Produktionssystem befindlichen Aufträgen) ▪ Einordnung in m Klassen muss möglich sein
<p>→ Geeignet für eine geringe Anzahl an Artikeltypen</p>	<p>→ Geeignet für eine große Anzahl an unterschiedlichen Artikeltypen</p>

Klassensicht empfehlenswert ist. Im Falle eines übergeordneten Agenten (z. B. Produktionssteuerer) und einer hohen Anzahl von Artikeln wirkt sich die Klassensicht sowohl auf die Trainingsdauer als auch auf die Lösungsqualität positiv aus.

5.3.3 Aktionsraum

Durch den Aktionsraum werden die möglichen Aktionen beschrieben, welche ein Agent wählen kann. Indem eine Aktion gewählt wird, interagiert der Agent mit seiner Umwelt (SUTTON & BARTO 2018). Die Aktionen, welche der Agent wählen kann, werden im Rahmen dieser Arbeit durch die im benutzerrollenspezifischen Informationsmodell enthaltenen Maßnahmen vorgegeben (siehe Abschnitt 4.2).

Für die Umsetzung der Produktionssteuerungsmaßnahmen in Aktionen der Agenten werden Grundtypen von Aktionen definiert (siehe Abbildung 5-6). Eine Kombination dieser Grundtypen ermöglicht die Umsetzung der Maßnahmen. Die im Rahmen dieser Arbeit verwendeten Grundtypen sind *Auftrag auswählen*, *Auftrag zuweisen*, *Pausiert* und *Parameter verändern*.

- **Auftrag zuweisen:** Das Zuweisen eines Auftrags ordnet diesen einem spezifischen Puffer vor einer Produktionsressource zu. Hierdurch erfolgt noch kein Start der Bearbeitung, allerdings kann der Auftrag anschließend zur Bearbeitung ausgewählt werden. Diese Aktion kann somit sowohl für die

Aufgabe der Auftragsfreigabe als auch für die Kapazitätssteuerung verwendet werden.

- **Auftrag auswählen:** Durch die Auswahl eines Auftrags wird ein spezifischer Auftrag aus einem Puffer, auf welchen der Agent Zugriff hat, ausgewählt und mit der Produktion begonnen. Mit der Auswahl des nächsten zu fertigenden Auftrags wird die Ist-Reihenfolge festgelegt. Die korrespondierende Aufgabe der Produktionssteuerung ist die Reihenfolgebildung.
- **Pausieren:** Bei dieser Aktion wählt der Agent keinen Auftrag aus und die Produktionsressource pausiert für eine definierte Anzahl von Zeitschritten.
- **Parameter verändern:** Hierbei können unterschiedliche Parameter (z. B. Bearbeitungsgeschwindigkeit) angepasst werden. Anpassungen sind sowohl auf Auftragsebene als auch auf Maschinenebene möglich. Allerdings können solche Anpassungen auch negative Auswirkungen (z. B. einen höheren Verschleiß durch eine höhere Bearbeitungsgeschwindigkeit) auf das Produktionssystem haben.

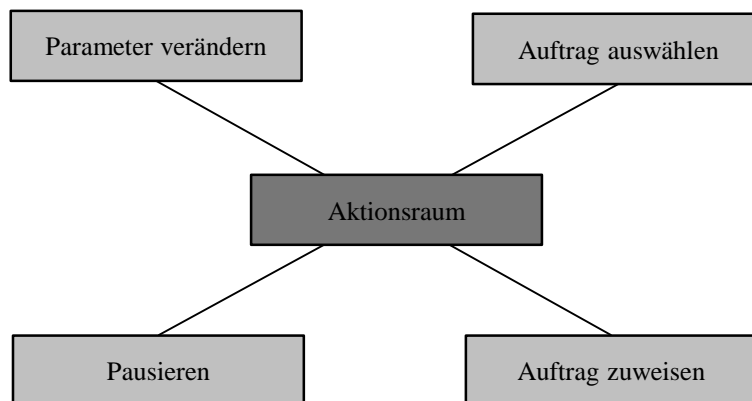


Abbildung 5-6: Grundtypen möglicher Aktionen der Agenten im Kontext der Produktionssteuerung

In Abbildung 5-7 wird beispielhaft die Gestaltung des Aktionsraums für einen Agenten gezeigt. Hierbei werden zwei unterschiedliche Agententypen verwendet. Agent 1 wählt Aufträge aus einer Quelle aus und weist diese spezifischen Puffern zu. Auf diese Puffer kann Agent 2.1 zugreifen und einen spezifischen Auftrag für den Produktionsstart auf Ressource 1.1, unter Berücksichtigung unterschiedlicher Randbedingungen (z. B. resultierende Rüstzeit), auswählen.

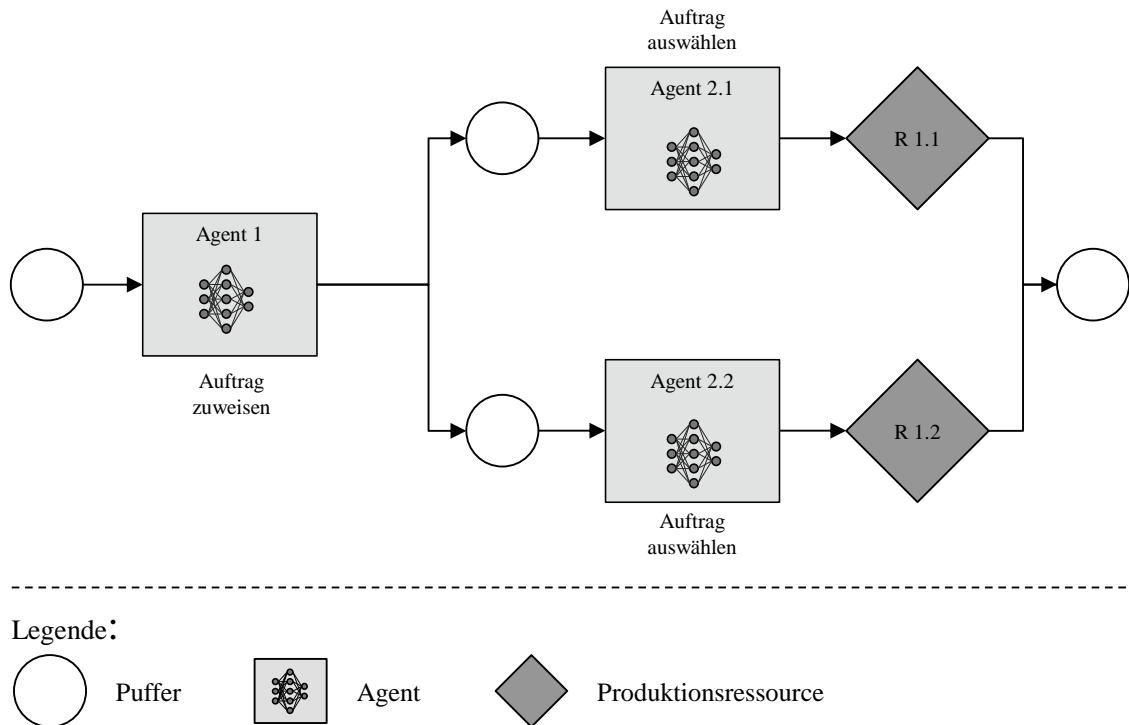


Abbildung 5-7: Beispielhafte Gestaltung unterschiedlicher Aktionen eines Agentensystems

5.4 Anpassung und Implementierung eines geeigneten Reinforcement-Learning-Verfahrens

Im Folgenden werden der im Rahmen dieser Arbeit verwendete DRL-Algorithmus sowie die notwendigen Bestandteile für dessen zielführenden Einsatz beschrieben. Mit Hilfe des Algorithmus wird die Strategie der Agenten, respektive die Gewichte der zugrunde liegenden neuronalen Netze, während der Trainingsphase angepasst. Die trainierten Agenten können nach dem erfolgreichen Abschluss des Trainings in Abhängigkeit vom aktuellen Systemzustand die bestmögliche Maßnahme auswählen. Mit Blick auf die in Abschnitt 5.3 eingeführten Kategorien der Entscheidungsunterstützung können mit Hilfe der trainierten Agenten die *Kategorie II* – Auswahl einer Maßnahme ohne Zusatzinformationen – sowie die *Kategorie III* – Auswahl einer Maßnahme mit Zusatzinformationen – realisiert werden.

5.4.1 Verwendeter Deep-Reinforcement-Learning-Algorithmus

Im Kontext des modellfreien Lernens kann eine weitere Unterscheidung in wertbasierte¹⁵ und strategiebasierte¹⁶ Verfahren vorgenommen werden. Wertbasierte Verfahren haben das Ziel, die Nutzenfunktion zu maximieren, wohingegen strategiebasierte Verfahren den Zusammenhang zwischen einem Zustand und der auszuführenden Aktion lernen. (SUTTON & BARTO 2018, ZHANG & YU 2020) Ein Verfahren, welches die Vorteile von strategie- und wertbasierten Verfahren vereint, ist der Actor-Critic-Ansatz (SUTTON & BARTO 2018, ZHANG & YU 2020). Im Rahmen dieser Arbeit wird als Lernverfahren der PPO-Algorithmus als Actor-Critic-Ansatz gewählt. Er zeichnet sich durch seine hohe Lösungsgüte und gute Generalisierungsfähigkeit bei gleichzeitig verhältnismäßig einfacher Implementierung aus. DNNs repräsentieren hierbei sowohl die Wertfunktion als auch die Strategie der Agenten. (SCHULMAN ET AL. 2017) Der Einsatz von DNNs ermöglicht eine hohe Reaktionsfähigkeit bei gleichzeitig hoher Performanz. Allerdings handelt es sich um einen Blackbox-Ansatz, sodass die Einflussfaktoren und somit die zugrunde liegende Entscheidungslogik nicht direkt nachvollzogen werden können.

Das Training und dadurch die Parametrierung eines DNN wird durch unterschiedliche Hyperparameter beeinflusst. Tabelle 5-2 gibt eine Übersicht über die für den

Tabelle 5-2: Ausgewählte Hyperparameter des PPO-Algorithmus (i. A. an OPENAI 2018)

Hyperparameter	Beschreibung
Lernrate	Veränderung der Parameter des DNN pro Iteration
Clipping	Parameter, der sicherstellt, dass sich die neue Strategie nicht zu weit von der alten Strategie entfernt
Diskontierungsfaktor	Parameter, welcher zur Bewertung von zukünftigen Belohnungen verwendet wird
Critic	Beschreibt, ob PPO als Actor-Critic-Ansatz ausgeführt werden soll
Aufbau DNN	Anzahl der Schichten und Neuronen pro Schicht
Aktivierungsfunktion	Beschreibt, welche Aktivierungsfunktion genutzt wird, um die Neuronen des DNN anzusprechen

¹⁵ Engl. *value-based*

¹⁶ Engl. *policy-based*

PPO-Algorithmus verwendeten Hyperparameter. Die bestmögliche Kombination derselben muss für jeden Anwendungsfall spezifisch mit Hilfe von Experimenten bestimmt werden. Dieser Vorgang ist auch als *Hyperparameter Tuning* bekannt und hat einen signifikanten Einfluss auf die Qualität der Entscheidungen, welche durch die Agenten getroffen werden. Zusätzlich zu den aufgeführten Hyperparametern beeinflussen der Trainingsaufbau sowie die Belohnungsfunktion die Strategie der Agenten.

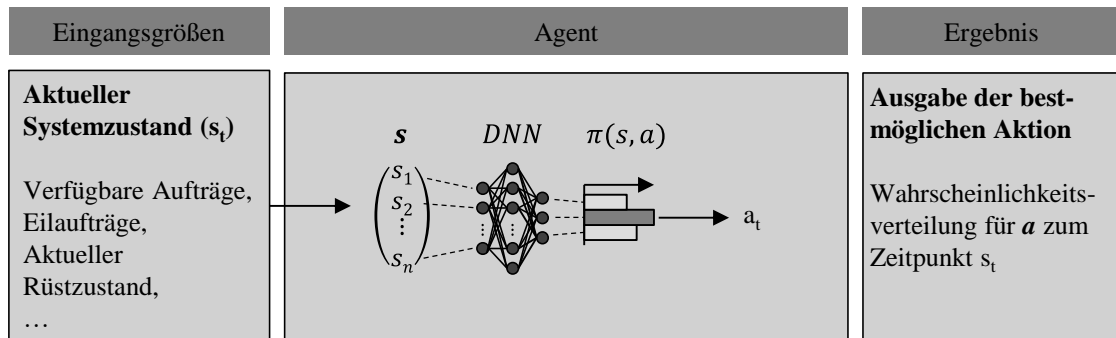


Abbildung 5-8: Ablauf der Aktionswahl durch den Agenten in Abhängigkeit von den Eingangsgrößen

Das Ergebnis des Trainings unter Verwendung von PPO ist eine erlernte Strategie, welche basierend auf dem Eingangsvektor die bestmögliche Aktion unter Berücksichtigung des Systemzustands – der Ausprägung von s – wählt (siehe Abbildung 5-8). Die bestmögliche Aktion entspricht dabei der Aktion, welche die größte Belohnung zum Zeitpunkt t verspricht. Die Ausgabeschicht des DNN wird dazu unter Verwendung bspw. der Softmax-Funktion¹⁷ in eine Wahrscheinlichkeitsfunktion umgewandelt. Die Aktion mit der größten Wahrscheinlichkeit zum Zeitpunkt t wird vom Agenten gewählt.

¹⁷ Die Softmax-Funktion wandelt einen Ausgabevektor $a = [a_1, a_2, \dots, a_n]$ in eine Wahrscheinlichkeitsverteilung um. Dadurch wird für alle Aktionen die Wahrscheinlichkeit berechnet, mit der im Zustand s die jeweilige Aktion a gewählt wird. Die Aktion mit der höchsten Wahrscheinlichkeit wird vom Agenten ausgewählt (RUSSELL & NORVIG 2010).

5.4.2 Trainingsaufbau

Für das Training der Agenten wird ein Simulationsmodell des Produktionssystems verwendet (siehe Abbildung 5-9). Somit kann die große Anzahl an Iterationen realisiert werden, welche für die Anpassung der neuronalen Netze unter Verwendung des PPO-Algorithmus notwendig ist. Ziel einer Simulation ist das „*Nachbilden eines Systems mit seinen dynamischen Prozessen in einem experimentierbaren Modell, um zu Erkenntnissen zu gelangen, die auf die Wirklichkeit übertragbar sind*“ (VDI 3633-1). Beim Training interagiert die Agentenumgebung mit dem Simulationsmodell über die Aktionen \mathbf{a}_t , den Zustand \mathbf{s}_t und die Belohnung \mathbf{R}_t . Durch die Belohnung, welche von der Leistung des Produktionssystems abhängt (siehe Abschnitt 5.4.3), erhalten die Agenten ein Feedback zur Güte der gewählten Aktionen. Entsprechend den Auswirkungen der Aktionswahl des Agenten erfolgt eine positive oder negative Belohnung. Diese Auswirkung der Aktionswahl wird durch ein Simulationsmodell des Produktionssystems bestimmt. Nach dem Abschluss einer Episode wird die Strategie der Agenten angepasst. Somit kann zukünftig ein besseres Verhalten der Agenten erzielt werden.

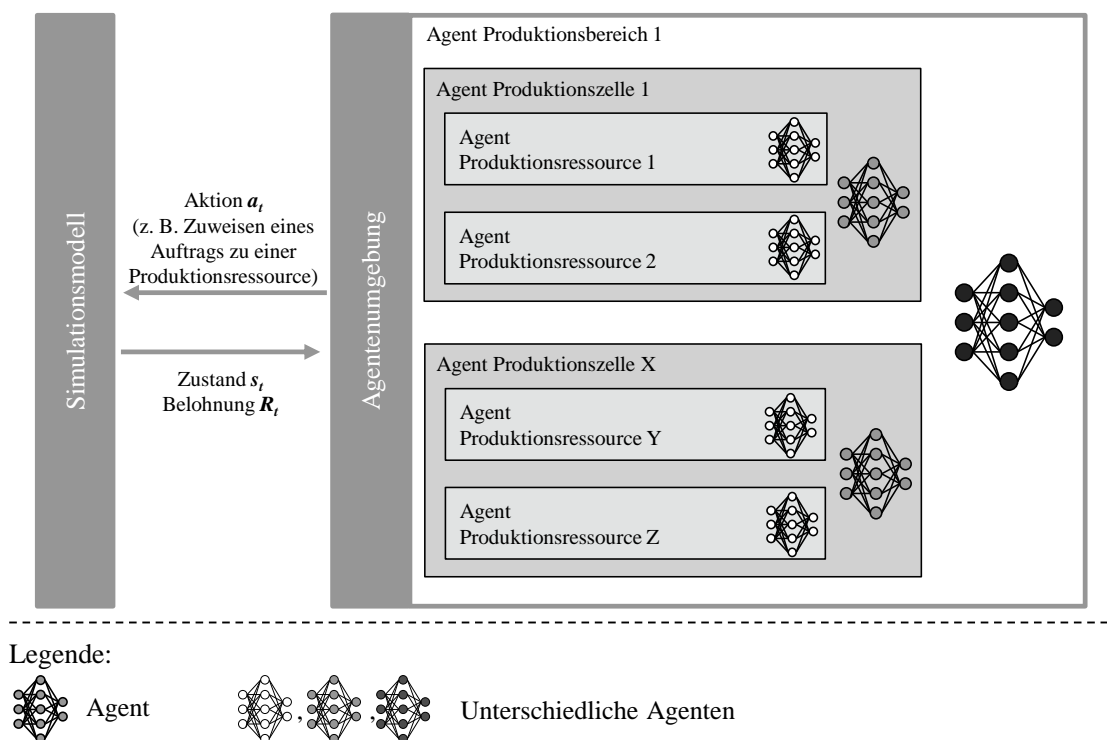


Abbildung 5-9: Hierarchischer Aufbau und Ablauf des Trainingsprozesses (i. A. an THEUMER ET AL. 2022)

5.4.3 Belohnungsfunktion

Im folgenden Abschnitt wird die Gestaltung der Belohnungsvergabe während des Trainings der Agenten näher beleuchtet. Sie hat entscheidenden Anteil an der Lösungsqualität des Systems. Nur eine zielgerichtete Belohnungsvergabe ermöglicht eine geeignete Reaktion der Agenten, bspw. auf ein unvorhergesehenes Ereignis, unter Berücksichtigung des aktuellen Zustands des Produktionssystems. Im produktionstechnischen Kontext kann es zielführend sein, die Belohnungsfunktion unter Einbezug der Kostenfunktion zu erstellen (vgl. RÖSCH 2021).

Eine Herausforderung, welche wesentlichen Einfluss auf das Lernverhalten der Agenten hat, ist der kausale Zusammenhang zwischen Aktionen und Belohnungen. Dieses Problem, auch als *Credit Assignment Problem* bekannt, beschreibt die Herausforderung, den Einfluss einer Vielzahl von Aktionen auf die erzielte Gesamtbelohnung zu quantifizieren. (MINSKY 1961, SUTTON & BARTO 2018) Insbesondere in einem Agentensystem wird diese Problematik verschärft (CHANG ET AL. 2003), da es in einem solchen gilt, die Fragestellung sowohl temporal als auch strukturell zu beantworten.

Prinzipiell kann durch die direkte (lokale) Vergabe einer Belohnung im Anschluss an eine Aktion die temporale sowie die strukturelle Komponente gelöst werden. Allerdings besteht hierbei die Gefahr, dass die Agenten in lokalen Optima verharren und die Optimierung des Gesamtsystems nicht erfolgt (POL ET AL. 2021).

Die im Rahmen dieser Arbeit verwendete Belohnungsfunktion besteht deshalb entsprechend Formel (5) anteilig aus einer lokalen Belohnung und einer globalen Belohnung. Somit können einerseits die temporale und die strukturelle Problematik der Belohnungsvergabe adressiert werden und andererseits wird das Risiko, in einem lokalen Optimum zu verharren, reduziert. Die Vergabe der lokalen Belohnung erfolgt direkt nach der Beendigung der jeweiligen Aktion. Hingegen wird die globale Belohnung am Ende der jeweiligen Episode vergeben.

$$B_{gesamt} = w_g B_{global} + w_l B_{lokal} \quad (5)$$

mit B_{gesamt}	Gesamtbelohnung
B_{global}	globale Belohnung
w_g	Gewichtungsfaktor der globalen Belohnung
B_{lokal}	lokale Belohnung
w_l	Gewichtungsfaktor der lokalen Belohnung

Durch die Gewichtungsfaktoren w_g und w_l kann die Bedeutung des jeweiligen Anteils während des Trainingsprozesses der Agenten angepasst werden (siehe Abschnitt 5.4.4). Zur Bestimmung der globalen Belohnung wird das von ZIPFEL ET AL. (2021) entwickelte System zur Bestimmung der operativen Produktionsperformanz (OPP) herangezogen. Das System teilt die Kosten in die in Abbildung 5-10 gezeigten Bestandteile ein. Für die exakte Zusammensetzung sei auf ZIPFEL ET AL. (2021) und ZIPFEL (2023) verwiesen.

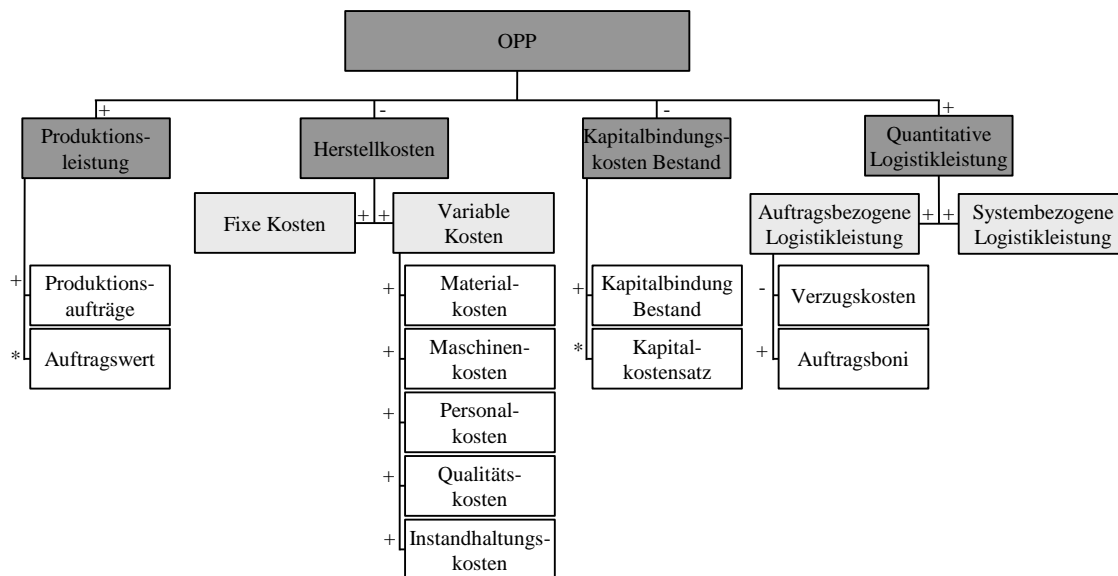


Abbildung 5-10: Kostenbestandteile des Systems zur Bestimmung der OPP (i. A. an ZIPFEL ET AL. 2021)

5.4.4 Training des Agentensystems

Die Gestaltung des Trainingsablaufs im Kontext von RL hat einen signifikanten Einfluss auf die notwendige Trainingsdauer bis zur Erreichung eines Konvergenzkriteriums sowie auf die resultierende Güte der durch die Agenten getroffenen Entscheidungen. Im Folgenden werden zwei Möglichkeiten beschrieben, welche die Trainingsdauer verringern und einen positiven Einfluss auf die Lösungsqualität haben. Die Verringerung der Trainingsdauer ist erstrebenswert, da sie die Skalierbarkeit des Systems fördert. Im Folgenden wird der *Trainingsablauf* im Allgemeinen sowie im Spezifischen der *Umgang mit ungültigen Aktionen* beschrieben.

Trainingsablauf

Prinzipiell kann zwischen einem zentralisierten und einem verteilten Trainingsablauf unterschieden werden. Ein zentralisiertes Training ist dadurch gekennzeichnet, dass Agenten basierend auf einer gemeinsamen Informationsbasis lernen. Dies bedeutet, dass unterschiedliche Agenten eines Agentensystems eine gemeinsame Strategie besitzen. Insbesondere wenn eine Vielzahl von Agenten eingesetzt wird, stellt die Skalierbarkeit eine Herausforderung für diesen Ansatz dar. Im Gegensatz dazu trainiert ein Agent beim verteilten Trainingsablauf unabhängig von anderen Agenten. (GRONAUER & DIEPOLD 2022) Für eine detaillierte Beschreibung des prinzipiellen Aufbaus sei auf WEIB (1995) und GRONAUER & DIEPOLD (2022) verwiesen. Im folgenden Abschnitt wird ein verteilter Trainingsansatz vorgestellt, welcher insbesondere beim Training zahlreicher Agenten eine Reduzierung der notwendigen Trainingsdauer bewirkt.

Hinsichtlich des idealen Trainingsablaufs haben die im Rahmen dieser Arbeit durchgeführten Simulationsstudien gezeigt, dass Curriculum Learning¹⁸ besonders vielversprechend hinsichtlich der erzielten Belohnung und der notwendigen Trainingsdauer ist. Hierbei gilt es, das zu lösende Problem in der ersten Stufe so klein wie möglich zu wählen (NARVEKAR ET AL. 2020, GRONAUER & DIEPOLD 2022). Durch Curriculum Learning kann die Skalierbarkeit des entwickelten Systems positiv beeinflusst werden (GRONAUER & DIEPOLD 2022). Mit zunehmender Zahl an Agenten nimmt die für das Erreichen eines Konvergenzkriteriums notwendige Trainingsdauer weiter zu. BENGIO ET AL. (2009) zeigen, dass sich der Einsatz von Curriculum Learning durch eine höhere Generalisierung sowie eine schnellere Konvergenz des Trainings vorteilhaft auf die erlernte Strategie der Agenten auswirkt.

Im Folgenden wird das Vorgehen für ein mehrstufiges Training der Agenten vorgestellt (siehe Abbildung 5-11). In Abhängigkeit von der Stufe unterscheidet sich sowohl die Anzahl der betrachteten Agenten als auch das verwendete Belohnungssignal. Durch die Anpassung des Belohnungssignals ändert sich ebenfalls die spezifische Zielsetzung der einzelnen Stufen.

In *Stufe I* des Trainings wird ein einzelner Agent trainiert. Hierdurch können für spezifische Agenten (z. B. Anlagenbedieneragent) wichtige Zusammenhänge (z. B. Auswirkung von Rüstungsvorgängen) gelernt werden. Prinzipiell empfiehlt es sich für die *Stufe I*, die lokale Belohnung stärker zu gewichten. Somit erhalten

¹⁸ Dt. *mehrstufiges Training*

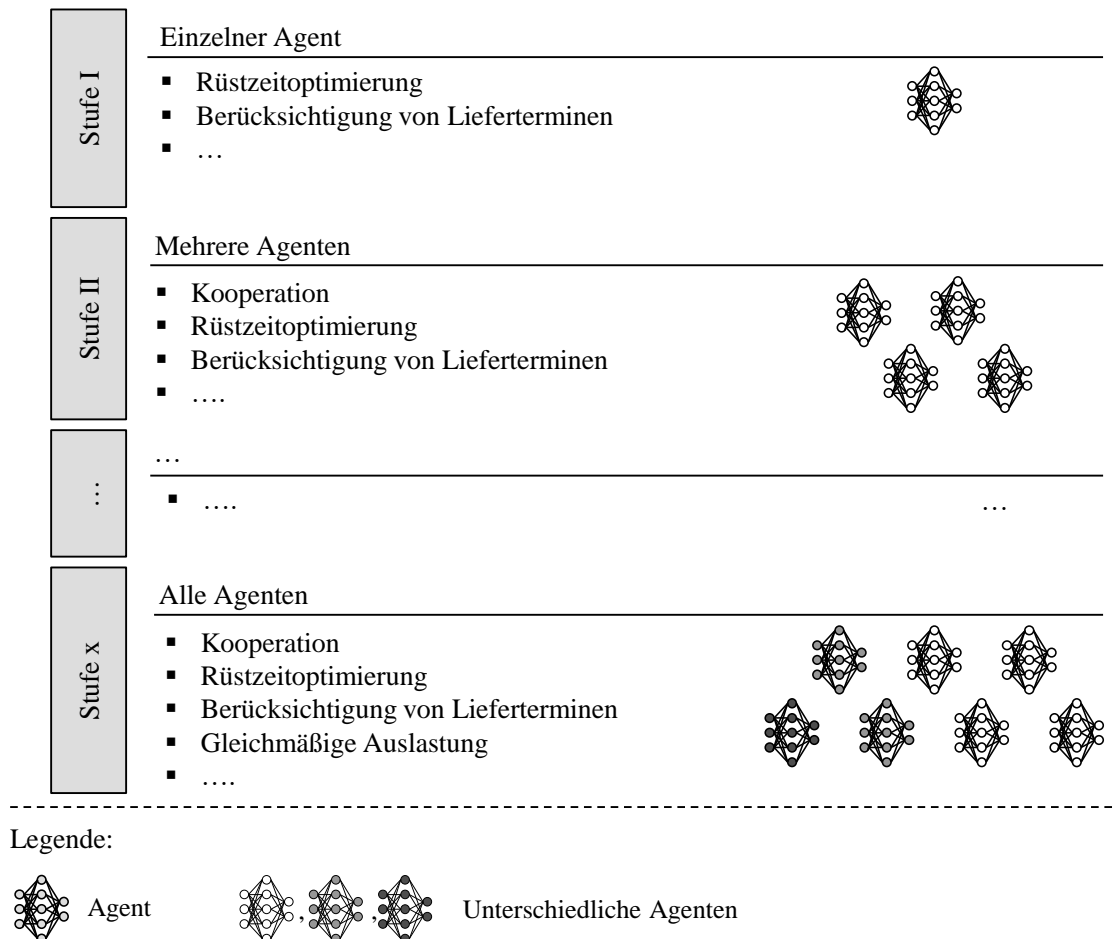


Abbildung 5-11: Beispielhafter Ablauf von Curriculum Learning in einem Agentensystem inklusive spezifischer Trainingsziele.

die Agenten ein direktes Feedback zu den gewählten Aktionen. Dies verkürzt die notwendige Trainingsdauer. Sobald eine Konvergenz des Lernvorgangs erkennbar ist, kann das Training gestoppt werden. Die gelernte Strategie kann nun für die Agenten verwendet werden, welche denselben Aktionsraum und Beobachtungsraum besitzen.

In *Stufe II* werden mehrere Agenten gleichzeitig trainiert (z. B. Agenten einer Hierarchieebene). Vor dem Training dieser Stufe werden die Agenten mit den aus Stufe I resultierenden Gewichten des KNN initialisiert. Somit handelt es sich um vortrainierte Agenten. In dieser Stufe gilt es, die Gewichtung der globalen Belohnung im Vergleich zur ersten Stufe zu erhöhen. Dadurch lernen die Agenten, miteinander zu kooperieren und gemeinsam das definierte Ziel (z. B. Erhöhung der Liefertreue) zu erreichen. Falls notwendig, können andere Agenten in *Stufe II* durch Heuristiken (z. B. FIFO) oder ebenfalls vortrainierte Strategien gesteuert

werden. Es gilt zu differenzieren, welche Agenten in dieser Stufe trainieren – es erfolgt eine Anpassung der Gewichte – und bei welchen Agenten die Gewichte festgehalten werden.

In *Stufe x* werden alle Agenten des Systems gemeinsam trainiert. Als Ausgangspunkt werden die in den vorherigen Stufen erlernten Strategien verwendet. Die Anzahl der vorherigen Stufen ist anwendungsfallsspezifisch – bspw. in Abhängigkeit von der Größe des Produktionssystems – festzulegen. Durch das gemeinsame Training aller Agenten wird deren Kooperation weiter verstärkt. In dieser Stufe gilt es die globale Belohnung am stärksten zu gewichten, um die Wahrscheinlichkeit eines lokalen Optimums zu verringern.

Der Einsatz von Curriculum Learning ermöglicht eine höhere Lösungsgüte bei gleichzeitig kürzerer Trainingsdauer des Agentensystems mit DRL. Durch das systematische Aufteilen unterschiedlicher Aufgaben sowie das dezidierte Training mit denselben wird die Voraussetzung für ein skalierbares, lernendes Agentensystem geschaffen.

Umgang mit ungültigen Aktionen

Eine der großen Herausforderungen im Kontext von RL ist der Umgang mit ungültigen Aktionen.¹⁹ Eine ungültige Aktion beschreibt das Ereignis, wenn ein Agent eine Aktion auswählt, welche zum Zeitpunkt der Aktionswahl aufgrund des aktuellen Systemzustands nicht möglich ist. Dies kann z. B. die Auswahl eines Auftrags sein, welcher zum Auswahlzeitpunkt nicht im System vorhanden ist und dementsprechend Systemzustands nicht auswählbar ist (RÖSCH 2021).

Prinzipiell kann mit diesem Problem auf zwei Arten umgegangen werden, welche sich durch unterschiedliche Charakteristika auszeichnen (siehe Tabelle 5-3). Einerseits kann eine *negative Belohnung* vergeben werden. Hierdurch lernt der Agent, während des Trainings ungültige Aktionen zu vermeiden. Eine andere Möglichkeit ist das sogenannte *Action Masking*.

Das Ziel bei der Vergabe einer negativen Belohnung ist, dass der Zusammenhang zwischen einer ungültigen Aktion und dem zugehörigen Zustand des Produktionssystems mit steigender Trainingsdauer in der Strategie der Agenten repräsentiert wird. Somit wählen die trainierten Agenten keine ungültigen Aktionen aus. Dies birgt, insbesondere in Trainingsepisoden mit einer großen Anzahl an Simulations-

¹⁹ Engl. *bad actions*

Tabelle 5-3: Charakteristische Eigenschaften von negativen Belohnungen und Action Masking im Umgang mit ungültigen Aktionen

Negative Belohnungen	Action Masking
Geringer Implementierungsaufwand	Mittlerer Implementierungsaufwand
Geringe Skalierbarkeit	Hohe Skalierbarkeit
Hohe Trainingsdauer	Geringe Trainingsdauer

schritten sowie einer globalen Belohnung, die Gefahr, dass keine Korrelation zwischen den ungültigen Aktionen und der Belohnung hergestellt werden kann. Durch eine lokale Belohnung, also die direkte Vergabe der Belohnung, kann dieser Effekt abgemildert werden.

Action Masking beinhaltet das mathematische Ausschließen von ungültigen Aktionen. Situationsabhängig wird hierbei die Strategie der Agenten unter Berücksichtigung des Zustands des Produktionssystems angepasst. Hierfür erhält der Agent, ergänzend zu seiner Beobachtung, eine Maske ungültiger Aktionen inv_s . Mit deren Hilfe können – vor dem Berechnen der Wahrscheinlichkeiten der Aktionen mit Hilfe der Softmax-Funktion – die mit den ungültigen Aktionen korrespondierenden Werte im Ausgabevektor durch eine negative Zahl N ersetzt werden. Daraus resultiert, dass die Wahrscheinlichkeit für die entsprechenden ungültigen Aktionen verschwindend gering wird. (HÖRMANN 2022, HUANG & ONTAÑÓN 2022)

Vorversuche haben gezeigt, dass sich Action Masking positiv auf die Trainingsdauer und die Lösungsgüte und somit auch positiv auf die Anforderung der Skalierbarkeit auswirkt. Insbesondere im Vergleich mit der Vergabe einer negativen Belohnung im Falle einer ungültigen Aktion bietet Action Masking im Kontext von DRL einen Vorteil (HUANG & ONTAÑÓN 2022).

5.5 Vorgehen zur unternehmensspezifischen Erstellung der lernenden benutzerrollenspezifischen Produktionssteuerung

Abbildung 5-12 zeigt den Ablauf der unternehmensspezifischen Anpassung der lernenden benutzerrollenspezifischen Produktionssteuerung. Zur unternehmensspezifischen Realisierung des Systems sind drei unterschiedliche Schritte notwendig.

Aufbau des Simulationsmodells

Damit Agenten in Kombination mit DRL das richtige Verhalten in Abhängigkeit vom Systemzustand lernen, ist eine Vielzahl von Iterationen notwendig. Insbesondere zu Beginn des Trainings, wenn noch viele zufällige Aktionen gewählt werden, ist die Lösungsqualität tendenziell gering. Das Verwenden einer Materialflusssimulation des Produktionssystems ermöglicht das Training des Agentensystems ohne negative Auswirkungen auf das Produktionssystem. Bei der Erstellung des Simulationsmodells des Produktionssystems mit dem Fokus, die für die Produktionssteuerung relevanten Charakteristika abzubilden, ist der gewählte Detaillierungsgrad von Bedeutung. Im Allgemeinen gilt für die Modellierung des Simulationsmodells der Leitsatz: „Die Nachbildung im Modell sollte so genau wie nötig,

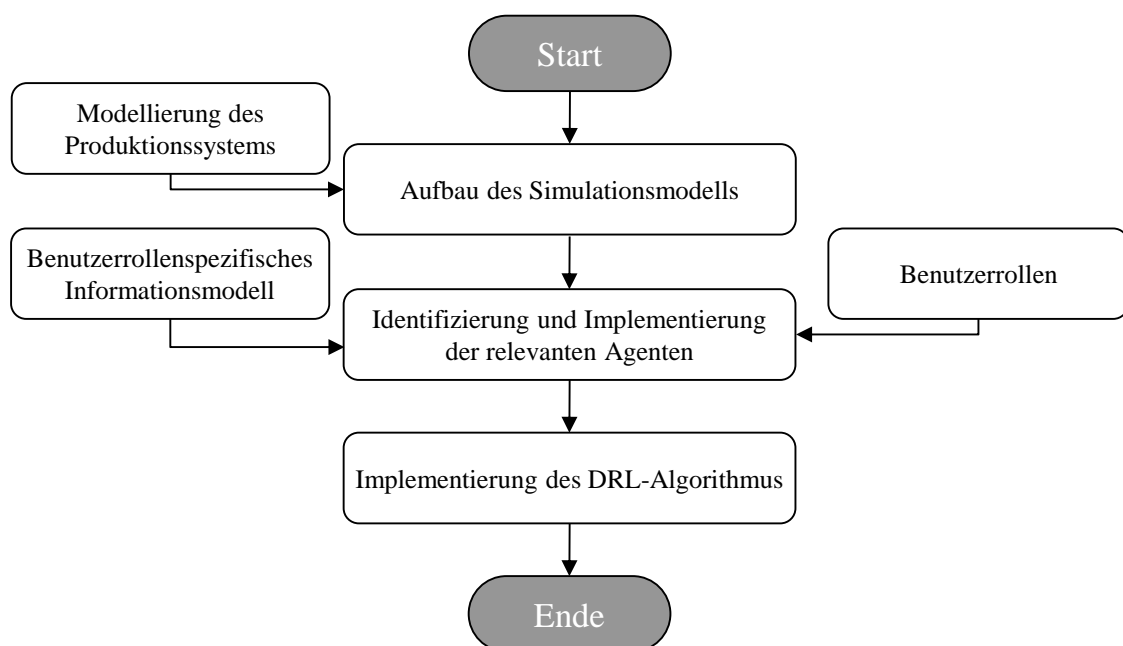


Abbildung 5-12: Ablauf der unternehmensspezifischen Anpassung der lernenden Produktionssteuerung

aber so abstrakt wie möglich erfolgen“ (REINHART 2000). Ist der Detaillierungsgrad zu hoch, steigen der Modellierungsaufwand, die Anfälligkeit für Fehler sowie die Laufzeit. Ein zu niedriger Detaillierungsgrad hingegen geht mit einer verminderten Aussagekraft und ggf. falschen Ergebnissen einher (REINHART 2000).

Diesem Leitsatz folgend, gilt es bei der Erstellung des Simulationsmodells des Produktionssystems im Kontext der vorliegenden Arbeit darauf zu achten, dass die für die Produktionssteuerung relevanten Eigenschaften ausreichend genau repräsentiert werden. Als Grundlage für die Modellierung des Simulationsmodells kann das Modell des Produktionssystems verwendet werden (siehe Abschnitt 5.2). Darin sind die für die Produktionssteuerung relevanten Informationen (z. B. Anlagenfähigkeitsmatrix, Rüstzeitmatrix) hinterlegt.

Identifizierung und Implementierung der relevanten Agenten

Für den Aufbau des Agentensystems ist es notwendig, unterschiedliche für das vorliegende Produktionssystem relevante Agententypen zu identifizieren. Basierend auf den in Abschnitt 4.5 identifizierten Benutzerrollen werden Grundtypen von Agenten erstellt. Sie dienen als Blaupause zum Ableiten spezifischer Agenten für den konkreten Anwendungsfall. Das in Abbildung 5-13 dargestellte Template

Allgemeine Informationen			
Name	Meister – PL 1		
Musterkategorie	Verbesserung der Auftragsfreigabe		
Agententyp	Meister	Benutzerrolle	Meister
Beschreibung	Der Meister – PL 1 hat die Aufgabe, für die Produktionslinie PL 1 die vorhandenen Aufträge unterschiedlichen Produktionsressourcen mit einer initialen Reihenfolge zuzuweisen.		
Anwendungsfall			
Kontext	Produktionssteuerung		
MAS-Architektur	Reaktiv		
Echtzeitfähigkeit	Weich		
Maßnahmen	Kapazitätssteuerung, Festlegung der initialen Reihenfolge		
Zustandsraum und Aktionsraum			
Zustandsraum	Klassensicht, Informationen über den Zustand untergeordneter Ressourcen		
Aktionsraum	Zuteilen von Aufträgen		
Zeitpunkt des Agierens	Auftreten einer Störung sowie eines Eilauftrags		
Lernverhalten			
Wissensbasis	Künstliches neuronales Netz		
Lernen, Wissensakquise	DRL, PPO als Actor-Critic		
Kooperation	Implizit durch gemeinsames Training mit anderen Agenten		
Sonstiges			
Implementierung	OpenAI Gym, RLlib		

Abbildung 5-13: Beispiel eines ausgefüllten Templates zur strukturierten Beschreibung von Agenten

dient der strukturierten Beschreibung der einzelnen Agenten. Grundlage sind die in Abschnitt 5.3 definierten Charakteristika von Agenten sowie das benutzerspezifische Informationsmodell (siehe Abschnitt 5.4).

Weiterhin ist es notwendig, die basierend auf dem Maßnahmenreferenzkatalog (siehe Abschnitt 4.2.2) identifizierten Maßnahmen der Produktionssteuerung in Aktionen umzuwandeln (siehe Abschnitt 5.3.3). Der so entstandene Aktionsraum bildet den Handlungsraum des entsprechenden Benutzers ab. Der Zustandsraum der Agenten beinhaltet die Informationen über den aktuellen Zustand des Produktionssystems, welche der jeweilige Agent als Grundlage für die Entscheidungsfindung benötigt. Somit kann erreicht werden, dass dem einzelnen Nutzer zielgerichtet Entscheidungen vorgeschlagen werden. Das Resultat ist eine Bereitstellung von Informationen für den richtigen Adressaten.

Implementierung des DRL-Algorithmus

Voraussetzung für die Realisierung der Kategorien II und III des Systems zur Entscheidungsunterstützung ist die Implementierung des DRL-Algorithmus. Beim Einsatz des DRL-Algorithmus gilt es, zwischen der Trainings- und der Anwendungsphase zu unterscheiden (siehe Abbildung 5-14). Während der Trainingsphase starten die Agenten entweder mit einem KNN mit zufällig initialisierten Gewichten oder im Falle des Curriculum Trainings (siehe Abschnitt 5.4.4) mit spezifischen, bereits vortrainierten Gewichten. Durch die Interaktionen mit dem Simulationsmodell erhält das Agentensystem über eine definierte Belohnungsfunktion Feedback zur Qualität der Aktionswahl. Im Rahmen der Trainingsphase basiert die Aktionswahl auf einer Mischung aus Exploration (zufällige Aktionswahl) und Exploitation (Nutzen des gelernten Wissens). Zur Verbesserung der Strategie des Agenten nimmt der Anteil der Exploration i. d. R. mit fortschreitendem Training ab. Das Ergebnis der Trainingsphase ist ein trainiertes Agentensystem, welches in einer Entscheidungssituation die Aktion wählt, welche im aktuellen Systemzustand das bestmögliche Ergebnis verspricht.

Das verwendete Simulationsmodell ist ausschließlich für die Trainingsphase, nicht aber für die Anwendungsphase der Agenten notwendig (siehe Abbildung 5-14). In diesem Fall kann das Agentensystem basierend auf den Produktionsdaten die bestmögliche Aktion auswählen. Eine Aktualisierung der Gewichte findet dabei nicht mehr statt.

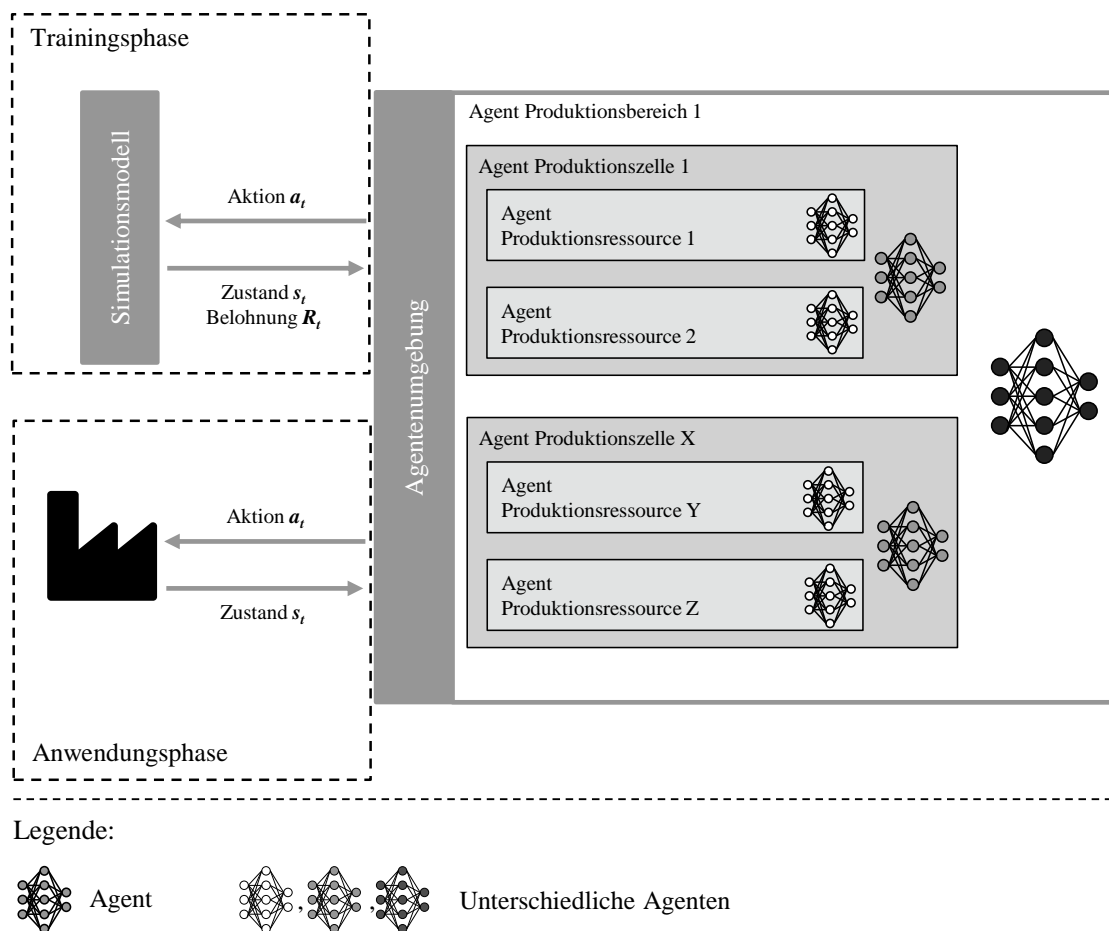


Abbildung 5-14: Differenzierung zwischen der Trainings- und der Anwendungsphase

5.6 Fazit

Im vorliegenden Kapitel wurde das auf DRL basierende benutzerrollenspezifische Partialsystem zur Produktionssteuerung vorgestellt. Zuerst wurde hierfür das Produktionssystem systematisch modelliert. Dies dient als Grundlage für den Aufbau des Simulationsmodells, welches den Trainingsprozess des Agentensystems ermöglicht. Anschließend wurde, aufbauend auf dem in Kapitel 4 entwickelten Informationsmodell, das Agentensystem konzeptioniert. Unterschiedliche Benutzerrollen werden durch eigene Agententypen mit spezifischen Beobachtungs- und Aktionsräumen abgebildet. Damit die entwickelten Agenten in Abhängigkeit vom aktuellen Zustand der Produktion die bestmögliche Aktion auswählen können, wurde ein geeignetes DRL-Verfahren angepasst und implementiert. Durch das so entstandene Agentensystem ist die Realisierung der Kategorien II und III der Entscheidungsunterstützung sichergestellt.

6 Erklärbarkeit von systemischen Entscheidungen

6.1 Allgemeines

Dieses Kapitel widmet sich der Erklärbarkeit von Handlungsempfehlungen, welche durch das in Kapitel 5 entwickelte Agentensystem erzeugt werden. Um die Akzeptanz für systemische Handlungsempfehlungen zu erhöhen, ist deren Erklärbarkeit unabdingbar. Die unterschiedlichen Erklärbarkeitsansätze bilden die Grundlage für die Realisierung der Kategorien IV und V des Systems zur Entscheidungsunterstützung. Ziel ist es hierbei, dem Nutzer in Entscheidungssituationen der Produktionssteuerung zusätzliche Erklärungen zur Funktionsweise des entwickelten Systems zur Entscheidungsunterstützung zur Verfügung zu stellen, um die Bias des Entscheidungsprozesses nach System 2 abzumildern.

Zuerst erfolgt eine Beschreibung der Integration der Erklärbarkeitsansätze in den Entscheidungsfindungsprozess (siehe Abschnitt 6.2). Anschließend werden in Abschnitt 6.3 unterschiedliche Erklärbarkeitsansätze klassifiziert und bewertet. Weiterhin wird auf die Adaption für den produktionstechnischen Kontext dieser Arbeit eingegangen. Abschließend wird in Abschnitt 6.4 die Integration ausgewählter Ansätze in das System zur Entscheidungsunterstützung im Kontext der Produktionssteuerung beschrieben. Hierdurch erfolgt auch die Integration der Erklärbarkeit in das System.

6.2 Integration der Erklärbarkeit von systemischen Entscheidungen in den Entscheidungsfindungsprozess

Der idealisierte Ablauf der Entscheidungsfindung ist in Abbildung 6-1 dargestellt. Nach dem Start der Produktion erfolgt der Produktionsablauf. Sollte ein Ereignis auftreten, welches eine Reaktion erfordert (z. B. eine Maschinenstörung), so erhält der entsprechende Mitarbeiter basierend auf dem aktuellen Zustand des Produktionssystems eine Handlungsempfehlung. Akzeptiert er diesen Handlungsvorschlag, wird die Maßnahme durch den Mitarbeiter initiiert. Akzeptiert er die vorgeschlagene Handlungsempfehlung nicht, kann eine tiefergehende Analyse erfol-

gen. Diese beinhaltet die Erklärung der Handlungsempfehlung. Unter Berücksichtigung zusätzlicher Informationen trifft der Mitarbeiter dann die Entscheidung und leitet die Maßnahmen ein. Anschließend wird der Produktionsablauf fortgesetzt.

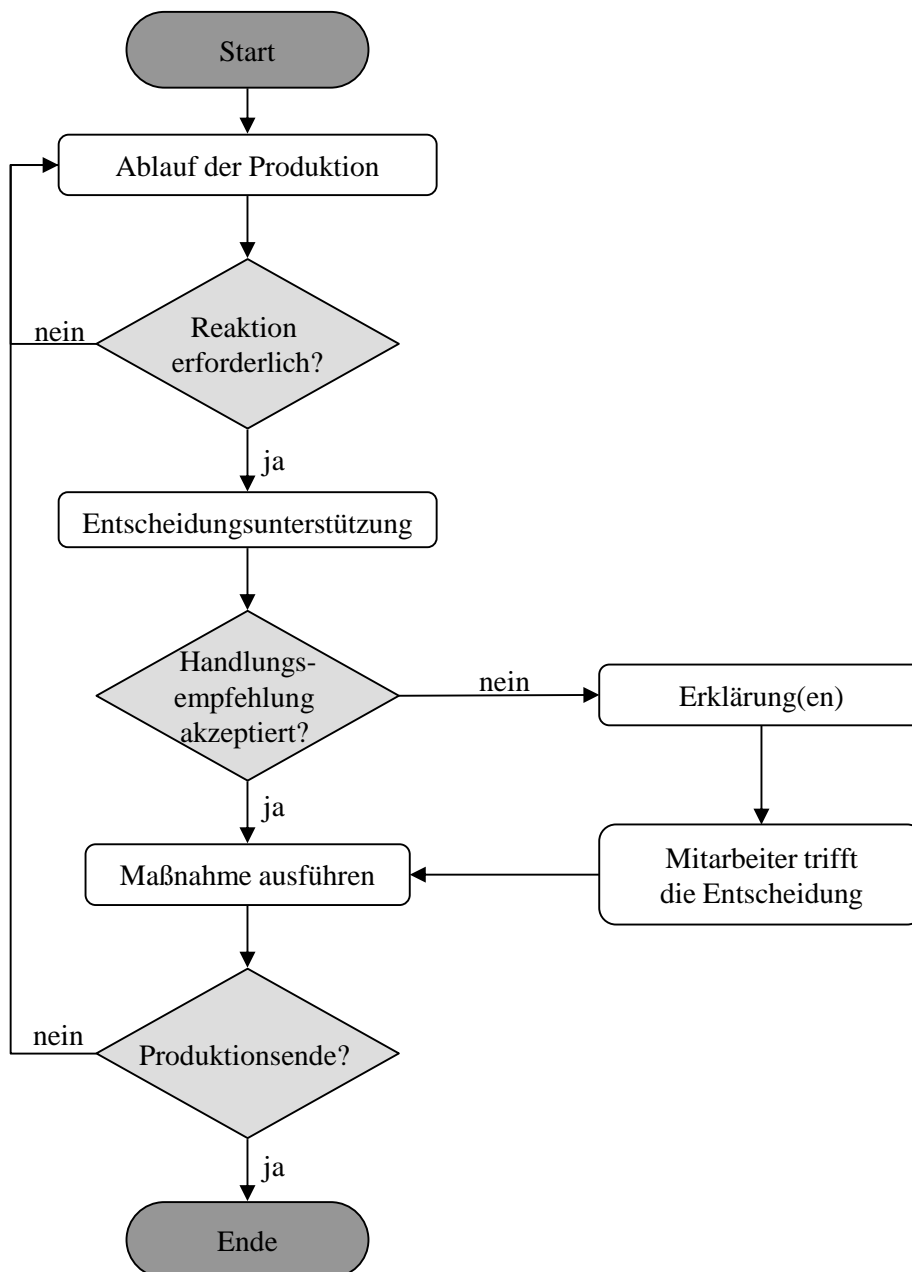


Abbildung 6-1: Idealisierter Ablauf der Entscheidungsfindung

6.3 Klassifizierung und Bewertung von Erklärbarkeitsansätzen

Für die Auswahl von Ansätzen zur Erklärbarkeit von Entscheidungen werden im Folgenden Kriterien beschrieben, anhand derer die unterschiedlichen Verfahren analysiert und bewertet werden können. Die Kriterien, mit deren Hilfe die Adäquanz der XAI-Verfahren im Kontext der Produktionssteuerung bewertet werden können, sind *Vorhersagegenauigkeit*, *Beschreibungsgenauigkeit*, *Dimension der Erklärbarkeit*, *Reaktionsfähigkeit* und *Art des Ansatzes* (siehe Abbildung 6-2).

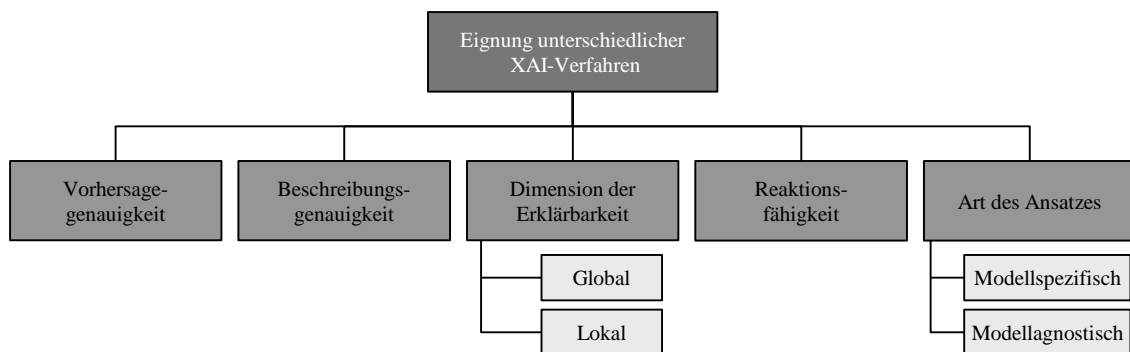


Abbildung 6-2: Charakteristika der Eignung unterschiedlicher XAI-Verfahren

Die Vorhersagegenauigkeit beschreibt die Fähigkeit eines ML-Modells, das dateninhärente Verhalten bzw. die dateninhärenten Zusammenhänge darzustellen. Falls das ML-Modell die in den Daten vorhandenen Zusammenhänge nicht lernt – und somit eine niedrige Vorhersagegenauigkeit besitzt – ist die Qualität aller durch das ML-Modell getroffenen Entscheidungen tendenziell gering (MURDOCH ET AL. 2019).

Das Kriterium *Beschreibungsgenauigkeit* erfasst den Grad, zu welchem ein XAI-Verfahren die von einem ML-Modell erlernten Zusammenhänge objektiv wiedergibt (MURDOCH ET AL. 2019). In Abbildung 6-3 ist schematisch der Zusammenhang zwischen der Vorhersage- und der Beschreibungsgenauigkeit bei der Erstellung und Erklärung eines ML-Modells aufgezeigt. Basierend auf den Daten wird ein Modell trainiert. Dieser Schritt beeinflusst die Vorhersagegenauigkeit des Modells. Wird für die Umsetzung eines Erklärbarkeitsansatzes ein Post-hoc-Verfahren gewählt, bleibt die Vorhersagegenauigkeit unverändert. Allerdings kann die Beschreibungsgenauigkeit durch den Einsatz von Post-hoc-Verfahren negativ beeinflusst werden.




Abbildung 6-3: Zusammenhang von Vorhersagegenauigkeit und Beschreibungsgenauigkeit für Post-hoc-Verfahren (i. A. an MURDOCH ET AL. 2019)

Die Dimension der Erklärbarkeit beschreibt, ob eine Analyse nur für eine einzelne Entscheidung durchgeführt wird oder ob das übergeordnete Verhalten des Modells analysiert wird. Die Reaktionsfähigkeit beschreibt die Rechenzeit, welche das Verfahren für die Generierung von Erklärungen benötigt. Dies ist insbesondere mit Blick auf die Produktionssteuerung ausschlaggebend. In diesem Kontext gilt es, das Anfallen der Rechenzeit weiter zu detaillieren. Einerseits kann diese vor dem produktiven Betrieb, beim Aufbau eines sogenannten Surrogatmodells, benötigt werden. Ein Surrogatmodell ermöglicht die Realisierung einer Post-hoc-Erklärbarkeit von opaken Modellen. Andererseits kann sie in der Anwendung anfallen, wenn Mitarbeiter eine Erklärung anfordern. Die Art des Ansatzes beschreibt die Art und Weise der Erzeugung der Erklärungen. Diese kann entweder modellspezifisch oder modellagnostisch sein. Ein modellspezifischer Ansatz ist ausschließlich für eine Art von Modellen einsetzbar. Ein modellagnostischer Ansatz hingegen besitzt diese Einschränkung nicht und kann prinzipiell in Kombination mit unterschiedlichen Arten von Modellen eingesetzt werden.

Tabelle 6-1: Bewertung unterschiedlicher Verfahren zur Generierung von Erklärungen für das von einem ML-Modell vorgeschlagene Ergebnis

	Transparente Modelle	Surrogatmodelle
Vorhersagegenauigkeit	-	+
Beschreibungsgenauigkeit	+	+
Globale Erklärungen	+	+
Lokale Erklärungen	0	+
Reaktionsfähigkeit	+	0
Modellagnostisch	-	0/+

Im Folgenden werden zwei unterschiedliche Modellarten – transparente Modelle und Surrogatmodelle – entsprechend den definierten Kriterien bewertet (siehe Tabelle 6-1). Das Kriterium der Vorhersagegenauigkeit ist insbesondere für transparente Verfahren von Relevanz (siehe Abschnitt 2.6.2). Wird hier aufgrund der Erklärbarkeit ein transparentes Modell (z. B. ein Entscheidungsbaum) gewählt, so kann dies die Vorhersagegenauigkeit im Vergleich mit opaken Lernverfahren reduzieren. Mit Hilfe von Surrogatmodellen können sowohl Modellerklärungen (globale Erklärungen) als auch Entscheidungserklärungen (lokale Erklärungen) generiert werden. Der Einfluss auf die Entscheidungen bei transparenten Modellen kann direkt ausgelesen werden, wohingegen für den Einsatz von Surrogatmodellen zur Generierung von Erklärungen weitere Schritte notwendig sind.

Insgesamt kann festgehalten werden, dass im Rahmen dieser Arbeit aufgrund der höheren Vorhersagegenauigkeit sowie der Unabhängigkeit vom gewählten Modell Ansätze aus der Kategorie der Post-hoc-Erklärbarkeit (siehe Abschnitt 2.6.2) weiterverfolgt werden. Allerdings muss die für die Surrogatmodelle notwendige Rechenzeit kritisch begutachtet und mit den Anforderungen der Produktionssteuerung abgeglichen werden.

Ein weiterer Ansatz zur Generierung lokaler Erklärungen ist die Berechnung von Kontrafaktualen. Diese beantworten im Gegensatz zu den Surrogatmodellen und transparenten Modellen nicht die Frage „Warum Aktion a?“, sondern die Frage „Warum nicht Aktion b?“. Mit Hilfe der Kontrafaktuale kann erklärt werden, welche Merkmale sich ändern müssen, damit eine andere Aktion durch das System vorgeschlagen wird. Statt der Einflussfaktoren für die Auswahl einer Aktion erzeugen die Kontrafaktuale den relativen Vergleich von Merkmalen für eine Entscheidung. Insbesondere für die Generierung von Erklärungen ist die Antwort auf diese kontrastive Fragestellung von Relevanz (HILTON 1990). Aufgrund der Nähe zum menschlichen Entscheidungsprozess wird dieser Ansatz im Rahmen der vorliegenden Arbeit ebenfalls untersucht.

Mit Hilfe des Surrogatmodells können die Kategorien IV und V des Systems zur Entscheidungsunterstützung realisiert werden. Die Kategorie V beinhaltet hierbei die globale Erklärung – also das allgemeine Verhalten – der spezifischen Agenten. Daraus kann abgeleitet werden, welche Merkmale relevant für die Aktionswahl der Agenten sind.

Dies bildet eine wichtige Voraussetzung für den Einsatz der Kontrafaktuale. Damit diese innerhalb der geforderten Antwortzeit Erklärungen liefern können, gilt es die

Anzahl der zu variierenden Merkmale festzulegen. Falls die Antwortzeit nicht erreicht werden kann, gilt es die Anzahl der variierenden Merkmale zu reduzieren. Dies kann mit Hilfe der globalen Erklärung erfolgen.

6.3.1 Merkmalsrelevanz

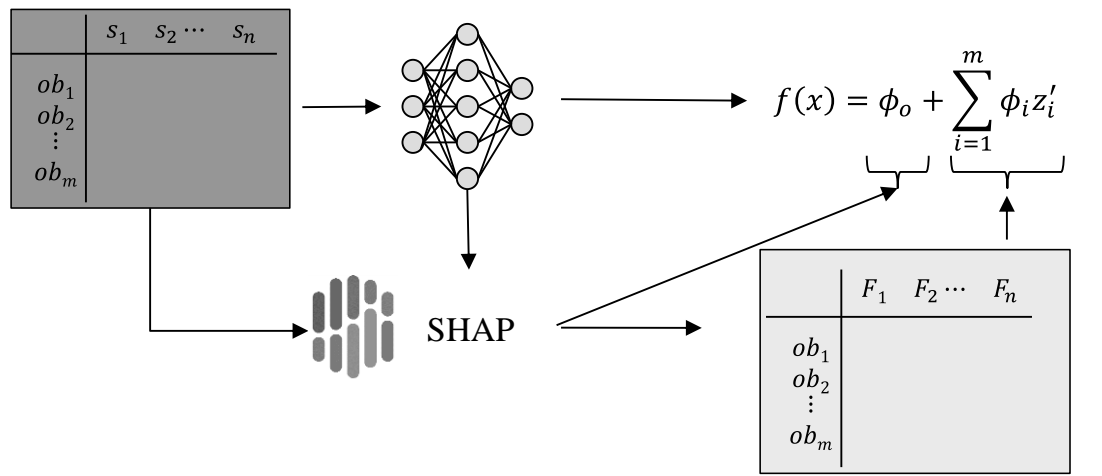
Surrogatmodelle, welche zur Kategorie *Merkmalsrelevanz* zählen, quantifizieren den Beitrag einzelner Merkmale zu einer bzw. mehreren Entscheidungen. Diese Quantifizierung erfolgt anhand eines numerischen Werts (ADADI & BERADA 2018, MURDOCH ET AL. 2019). Die Bestimmung des Beitrags erlaubt die Realisierung sowohl einer lokalen als auch einer globalen Erklärbarkeit. Wird die Methode für die lokale Erklärbarkeit einer Entscheidung verwendet, so hat das Ergebnis nur lokale Gültigkeit. Es kann dementsprechend nicht auf das allgemeine Verhalten des Modells geschlossen werden. (MURDOCH ET AL. 2019, MOLNAR 2022) Für die globale Erklärbarkeit wird der Beitrag einzelner Merkmale für den vollständigen Datensatz – und damit eine Vielzahl von Entscheidungen – berechnet. Hierdurch können für die Auswahl des ML-Modells tendenziell wichtige Merkmale identifiziert werden. Allerdings kann nicht auf deren Bedeutung für eine lokale Entscheidung geschlossen werden. (MURDOCH ET AL. 2019)

In der vorliegenden Arbeit wird für die Realisierung sowohl der lokalen als auch der globalen Erklärbarkeit das Verfahren SHapley Additive exPlanations (SHAP) verwendet, welches die Merkmalsrelevanz bestimmt (LUNDBERG & LEE 2017). Bei SHAP handelt es sich um einen modellagnostischen Ansatz, welcher auf den Shapley-Werten, einem Konzept aus der Spieltheorie, beruht (LUNDBERG & LEE 2017). Mit Hilfe der Shapley-Werte kann der Beitrag eines Spielers zum Ergebnis eines Spiels berechnet werden. Durch das Berechnen des Ergebnisses für jede mögliche Koalition kann der durchschnittliche Beitrag jedes Spielers ermittelt werden (SHAPLEY 1953). Die Anzahl der für die Bestimmung der Shapley-Werte notwendigen Rechenoperationen steigt exponentiell mit der Anzahl der Merkmale (MOLNAR 2022).

Ausgehend von dieser spieltheoretischen Grundlage approximiert SHAP die Shapley-Werte und damit die Relevanz bzw. den Einfluss einzelner Merkmale für bzw. auf das Ergebnis. Somit kann die Rechendauer für die Generierung von Erklärungen bei akzeptabler Aussagekraft derselben reduziert werden. (LUNDBERG & LEE 2017) Hierbei entsprechen Merkmale den Spielern, das ML-Modell dem Spiel und die Vorhersage der Auszahlung (LUNDBERG & LEE 2017). Der Einsatz von SHAP bietet den Vorteil eines modellagnostischen Verfahrens, das eine vielfältige

Einsatzmöglichkeit bietet. Gleichzeitig gibt es die Möglichkeit eines modellspezifischen Einsatzes (z. B. Baumalgorithmen mit Gradientenverstärkung, DNN), welcher die notwendige Rechendauer weiter reduziert (LUNDBERG & LEE 2017). Im Rahmen dieser Arbeit werden zwei unterschiedliche SHAP-Solver untersucht: einerseits Kernel SHAP, ein modellagnostischer Solver, und andererseits Deep SHAP, ein modellspezifischer Solver für DNN.

SHAP benötigt zum Berechnen der SHAP-Werte und damit zur Quantifizierung des Einflusses einzelner Merkmale auf die Entscheidung einerseits das trainierte Modell eines Agenten sowie andererseits einen Hintergrunddatensatz (siehe Abbildung 6-4).



Legende:

- Hintergrunddatensatz, bestehend aus den Zustandsvektoren s der Beobachtung ob_m
- Tabelle mit berechneten SHAP-Werten F_n
- Trainiertes Modell eines Agenten
- $f(x)$: Ausgewählte Aktion des Agenten
- ϕ_o : Durchschnittlicher Erwartungswert
- $\sum_{i=1}^m \phi_i z'_i$: Summe der aufsummierten SHAP-Werte

Abbildung 6-4: Interaktion zwischen dem Beobachtungsraum, dem Agenten und der SHAP-Bibliothek zur Approximation der SHAP-Werte (i. A. an COOPER 2021)

Der Hintergrunddatensatz stellt die Grundlage für die Bildung unterschiedlicher Merkmalskoalitionen zur Berechnung der SHAP-Werte dar. Wenn ein Merkmal in einer Koalition nicht auftritt, wird aus dem Datensatz für diese Merkmale ein Mittelwert berechnet. Dies ist notwendig, da KNNs nicht mit fehlenden Eingangswerten umgehen können. Der Hintergrunddatensatz beinhaltet die Werte der Merkmale für jede Beobachtung, welche im Betrieb des Agentensystems aufgetreten sind. Diese entsprechen den jeweiligen Beobachtungen des Agenten – dem

Zustand des Produktionssystems zum gegebenen Zeitpunkt – und bilden die Grundlage für die Aktionswahl durch den Agenten. Durch die Permutation einzelner Beobachtungen wird das Surrogatmodell g der additiven Merkmalsrelevanz zu

$$g(z') = \Phi_0 + \sum_{i=1}^M \Phi_i z'_i \quad (6)$$

mit $g(z')$	Surrogatmodell
Φ_0	Durchschnittlicher Erwartungswert
M	Max. Größe der Koalition
Φ_i	Beitrag eines Merkmals i
z'_i	Vektor der Koalition

berechnet. (LUNDBERG & LEE 2017) Durch das Lösen der gewichteten linearen Funktion mittels eines linearen Regressionsmodells können die SHAP-Werte berechnet werden. Hierbei gilt es die Verlustfunktion

$$L(\hat{f}, g, \pi_x) = \sum_{z' \in Z} [\hat{f}(h_x(z')) - g(z')]^2 \pi_{x'}(z') \quad (7)$$

mit $L(\hat{f}, g, \pi_x)$	Verlustfunktion
$\hat{f}(h_x(z'))$	Vorhersagemodell
$\pi_{x'}(z')$	SHAP Kernel

zu minimieren. (LUNDBERG & LEE 2017) Den in der Verlustfunktion enthaltenen SHAP Kernel gilt es entsprechend

$$\pi_{x'}(z') = \frac{(M - 1)}{(M \text{ choose } |z'|) |z'| (M - |z'|)} \quad (8)$$

mit $\pi_{x'}(z')$	SHAP Kernel
M	Max. Größe der Koalition
$ z' $	Anzahl der Elemente, für die gilt: $z' \neq 0$

zu berechnen. (LUNDBERG & LEE 2017)

Die approximierten SHAP-Werte ergeben sich als Lösung des gewichteten linearen Regressionsproblems und ermöglichen die Generierung von sowohl lokalen als auch globalen Erklärungen. Mit dem Kernel-SHAP-Ansatz können unabhängig vom gewählten Verfahren sowohl lokale als auch globale Erklärungen erzeugt

werden. Somit wird die Wahl der Lernverfahren nicht eingeschränkt. Für die Beschreibung des modellspezifischen Deep-SHAP-Ansatzes sei auf den Anhang 14.2 verwiesen.

Globale Erklärbarkeit

Für die Realisierung der globalen Erklärbarkeit werden die SHAP-Werte einer Vielzahl von Beobachtungen – bzw. des gesamten Datensatzes – mit Hilfe eines SHAP-Solvers berechnet. Somit wird eine Aussage über die tendenzielle Bedeutung einzelner Merkmale ermöglicht. Abbildung 6-5 zeigt beispielhaft den Einfluss unterschiedlicher Merkmale auf die Entscheidungen eines Modells. Die gewonnenen Erkenntnisse über den Einfluss einzelner Merkmale auf das ML-Modell respektive auf die Entscheidungen der Agenten können vielfältig verwendet werden. Einerseits kann das Modell bereits während der Entwicklung überprüft werden. Somit können frühzeitig mögliche Fehler und/oder Bias im Modell selbst identifiziert und behoben werden. Andererseits können für Entscheidungen des Modells irrelevante Merkmale bestimmt werden. Diese können anschließend aus dem Trainingsprozess der Agenten exkludiert werden. Eine geringe Anzahl an irrelevanten Merkmalen reduziert die notwendige Trainingsdauer und erhöht gleichzeitig die Qualität der Lösungen.




Abbildung 6-5: Beispielhafte Visualisierung der Bedeutung einzelner Merkmale anhand ihrer SHAP-Werte

Lokale Erklärbarkeit

Der Einfluss einzelner Merkmale auf eine Entscheidung kann ebenfalls mit Hilfe der SHAP-Werte dargestellt werden. Ausgehend von der erwarteten Ausgabe des

ML-Modells – und damit der erwarteten Entscheidung – wird der marginale Beitrag einzelner Merkmale zur Veränderung der Entscheidung berechnet. Dieser ist für den Fall der lokalen Erklärbarkeit einzig vom aktuellen Produktionszustand abhängig. Abbildung 6-6 zeigt eine Visualisierung der lokalen Erklärbarkeit. Anhand der unterschiedlichen Grautöne wird gekennzeichnet, ob das Merkmal zu einer Erhöhung oder zu einer Reduktion der erwarteten Ausgabe führt. Durch die lokale Erklärung einer Entscheidung kann der Mitarbeiter in einer Entscheidungssituation einen direkten Einblick in die spezifisch dieser Entscheidung zugrunde liegenden Einflussfaktoren erhalten.

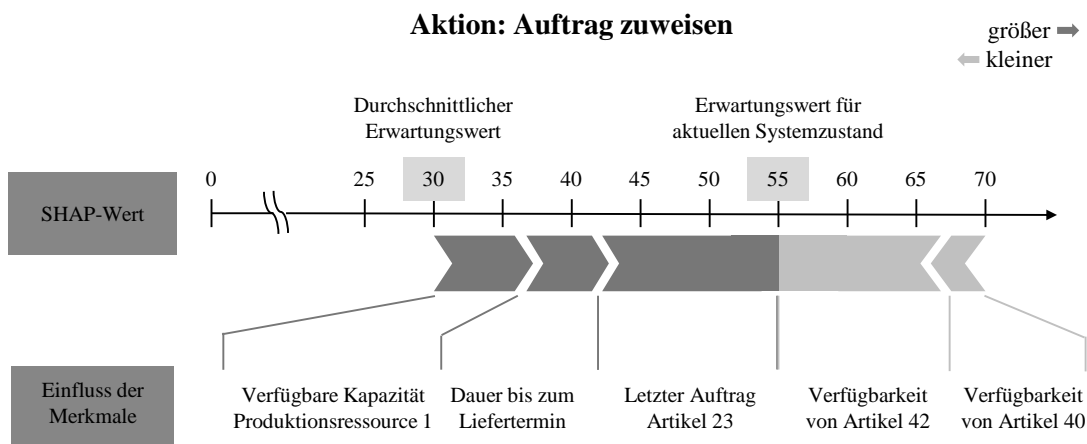


Abbildung 6-6: Einflussfaktoren auf eine einzelne Entscheidung (i. A. an THEUMER ET AL. 2022)

6.3.2 Kontrafaktuale

Die Berechnung von Kontrafaktualen dient der Erzeugung lokaler Erklärungen. Kontrafaktuale lassen sich mit Hilfe einer vordefinierten Struktur als textuelle Ausgabe den Nutzern zur Verfügung stellen. Dies bietet den Vorteil einer hohen Verständlichkeit bei gleichzeitig geringem Analyseaufwand für die Nutzer. Aufgrund der Repräsentation der unterschiedlichen Benutzergruppen durch Agenten ist es möglich, den Benutzern ausschließlich die Kontrafaktuale zur Verfügung zu stellen, welche sie betreffen. Die Definition von Kontrafaktualen sowie ein exemplarisches Kontrafaktual sind in Abbildung 6-7 dargestellt.

Das Ziel bei der Berechnung eines Kontrafaktuals ist es, die Distanz zur ursprünglichen Ausgabe möglichst gering zu halten. Damit ist gemeint, dass möglichst geringe Veränderungen am Ausgangszustand für die Berechnung der Kontrafaktuale vorgenommen werden. Würde hingegen ein Kontrafaktual erzeugt, welches weit

vom ursprünglichen Zustand entfernt ist, wäre die Relevanz des berechneten Kontrafaktuals nicht mehr gegeben.

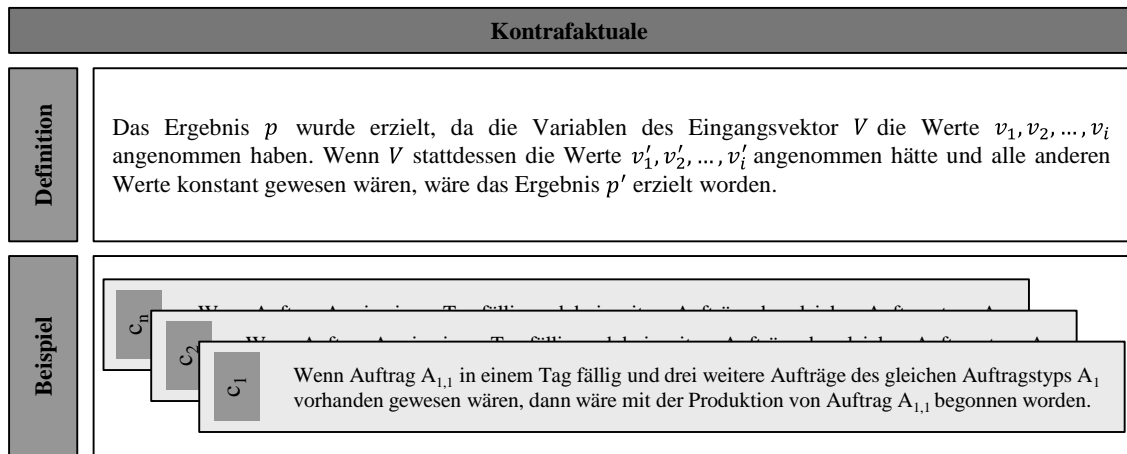


Abbildung 6-7: Definition eines Kontrafaktuals nach WACHTER ET AL. (2018) sowie die beispielhafte textuelle Ausgabe eines Kontrafaktuals

Die Berechnung von Kontrafaktualen erfolgt nach WACHTER ET AL. (2018) und MOTHILAL ET AL. (2020) – in Form einer Optimierungsaufgabe – entsprechend Formel (9). Das Kontrafaktual c wird durch die Berechnung des Minimums der aufgeführten Funktion gebildet. Die Verlustfunktion y_{loss} beschreibt den Unterschied zwischen der ursprünglichen Ausgabe y und der neuen Ausgabe $f(c)$. Durch den zusätzlichen Term $|x - c|$ wird die zu minimierende Entfernung zwischen dem Kontrafaktual und dem ursprünglichen Eingabevektor berücksichtigt.

$$c = \arg \min_c y_{loss}(f(c), y) + |x - c| \tag{9}$$

- mit c Kontrafaktual
- $f(c)$ Ausgabe des Blackbox-Modells für das Kontrafaktual
- y Ursprüngliche Ausgabe
- x Ursprünglicher Eingabevektor

MOTHILAL ET AL. (2020) weisen darauf hin, dass es vorteilhaft ist, den Benutzern mehrere Kontrafaktuale zur Verfügung zu stellen, um einzelne Entscheidungen zu erklären. Daher wird die Berechnung der Kontrafaktuale um einen gewichteten Diversitätsterm (*diversity*) erweitert. Mit Hilfe dieses Terms können sich voneinander unterscheidende Kontrafaktuale erzeugt werden. Zusätzlich wird eine gewichtete durchschnittliche Distanz zwischen dem ursprünglichen Eingabevektor

und den Kontrafaktualen c_i berechnet. Somit ist es möglich, nicht ein einzelnes Kontrafaktual, sondern k Kontrafaktuale mit

$$\mathbf{C}(\mathbf{x}) = \arg \min_c \frac{1}{k} \sum_{i=1}^k yloss(f(\mathbf{c}_i), a_{erw}) + \frac{\lambda_1}{k} \sum_{i=1}^k dist(\mathbf{c}_i, \mathbf{x}) - \lambda_2 diversity(\mathbf{c}_1, \dots, \mathbf{c}_k) \quad (10)$$

mit k	Anzahl der Kontrafaktuale
\mathbf{c}_i	Kontrafaktual
$yloss(f(\mathbf{c}_i), y)$	Verlustfunktion
a_{erw}	Erwartete Ausgabe
λ	Hyperparameter zur Gewichtung einzelner Terme
$f(c)$	Ausgabe des Blackbox-Modells für das Kontrafaktual
$diversity$	Diversitätsterm

zu berechnen (MOTHILAL ET AL. 2020). Zur Lösung dieser Gleichung – und damit zur Berechnung der Kontrafaktuale – wird ein genetischer Algorithmus eingesetzt, welcher die Verlustfunktion als Zielfunktion (siehe Formel (10)) minimiert.

Indem Entscheidern die Möglichkeit gegeben wird, ihre Entscheidung, welche sie durch das Anwenden des Systems 1 (siehe Abschnitt 4.3) getroffen haben, als Referenz anzugeben, bekommen sie die Rückmeldung, für welchen Systemzustand bzw. welche Systemzustände diese Entscheidung gewählt worden wäre.

Herausfordernd ist in diesem Kontext die Auswahl der Merkmale, welche mit Hilfe des genetischen Algorithmus variiert werden sollen. Die Anzahl der verwendeten Merkmale sollte möglichst gering gewählt werden, um die Benutzer nicht mit zu vielen Kontrafaktualen zu überfordern (MOTHILAL ET AL. 2020). Gleichzeitig gilt es, die Anzahl der Merkmale nicht zu gering zu wählen, um keine relevanten Informationen zu supprimieren. Auf einen möglichen Lösungsansatz für diese Problematik wird in Abschnitt 6.3.3 detailliert eingegangen.

6.3.3 Verknüpfung der Verfahren

Die Auswahl der Merkmale, welche bei der Generierung der Kontrafaktuale variiert werden, kann durch die Berechnung der globalen Bedeutung der Merkmale durch SHAP stattfinden. Somit können gezielt diejenigen Merkmale ausgewählt werden, welche den größten Einfluss auf die Entscheidung besitzen. Die Anzahl der verwendeten Merkmale muss hierbei fallspezifisch bestimmt werden und hängt einerseits von der für eine Entscheidung zur Verfügung stehenden Zeit, andererseits von der für die Berechnung der Kontrafaktuale notwendigen Zeit ab. Mit steigender Anzahl der Merkmale nimmt die notwendige Berechnungsdauer der Kontrafaktuale zu. Andererseits sollte die Anzahl der Merkmale, unabhängig von der Rechenzeit, einen gewissen Schwellenwert nicht übersteigen, um Mitarbeiter nicht zu überfordern (MOTHILAL ET AL. 2020). Abbildung 6-8 zeigt das Vorgehen zur Reduzierung der Merkmale für die Berechnung der Kontrafaktuale. Allgemein gilt es zu beachten, dass ein Gleichgewicht zwischen der Antwortzeit und der Qualität der Erklärungen herrscht.

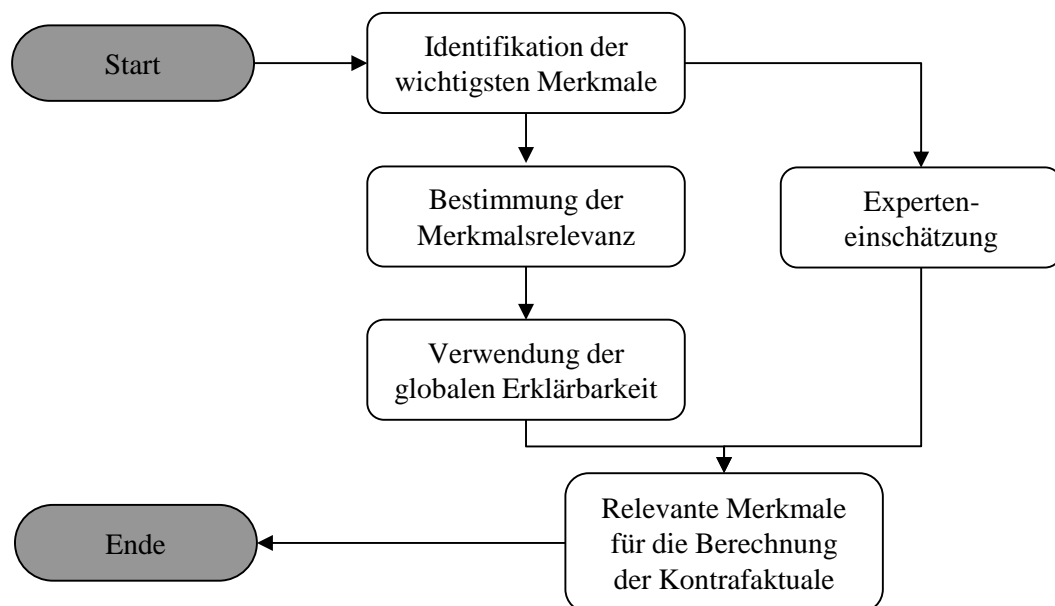


Abbildung 6-8: Verknüpfung des Verfahrens zur Bestimmung der Merkmalsrelevanz mit dem Verfahren zur Generierung von Kontrafaktualen

6.4 Vorgehen zur Integration in das lernende System zur Entscheidungsunterstützung

Das Modul zur Generierung von Erklärungen benötigt ebenfalls unternehmensspezifische Anpassungen, damit eine zielgerichtete Realisierung der Kategorien IV

und V der Entscheidungsunterstützung erfolgen kann. Abbildung 6-9 zeigt die notwendigen Schritte zur unternehmensspezifischen Anpassung. Diese bestehen aus der *Implementierung und Adaption der Verfahren*, der *Integration in das lernende System* und der *Generierung von lokalen und globalen Erklärungen*.

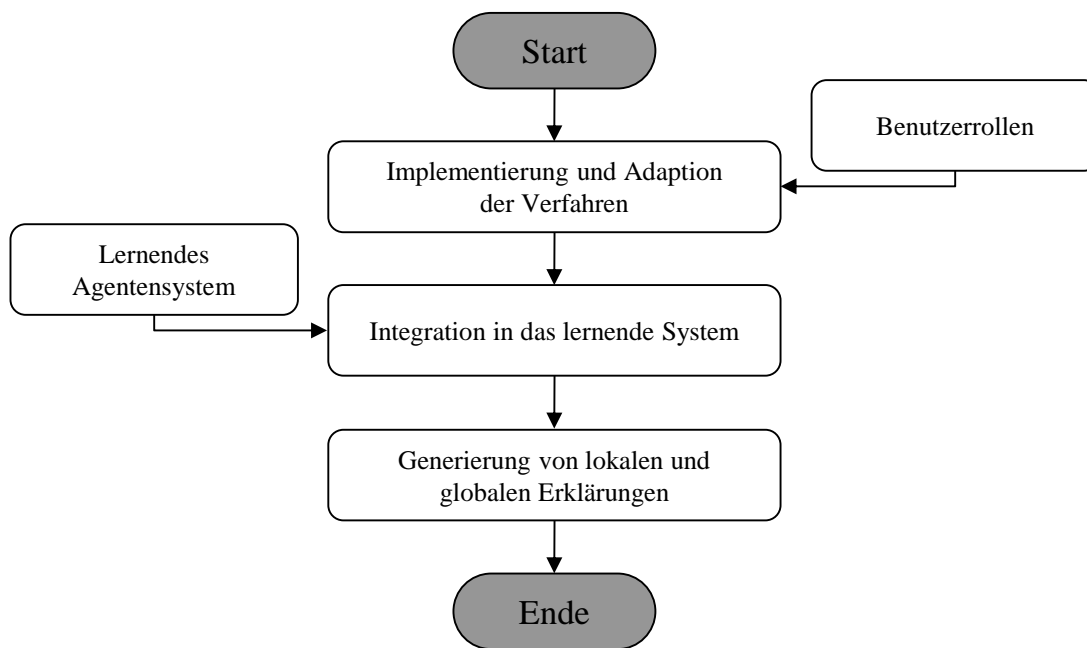


Abbildung 6-9: Ablauf der Integration von Erklärbarkeitsansätzen in das System zur Entscheidungsunterstützung

Im Rahmen der Implementierung und Adaption der Verfahren zur Erklärbarkeit werden die ausgewählten Ansätze an den spezifischen Anwendungsfall angepasst. Hierunter fällt u. a. die Definition der Anforderungen an die Generierung der Erklärungen. Erklärungen, welche mit Hilfe des Ansatzes zur Bestimmung der Merkmalsrelevanz erzeugt werden, können auch bei einer hohen Anzahl an Merkmalen innerhalb weniger Sekunden erzeugt werden. Aufgrund der Berechnung der Kontrafaktuale mit Hilfe eines genetischen Algorithmus steigt der notwendige Rechenaufwand exponentiell mit der Anzahl der Merkmale. In Abbildung 6-10 wird der Zusammenhang zwischen notwendiger Rechenzeit und der Anzahl der Merkmale dargestellt.


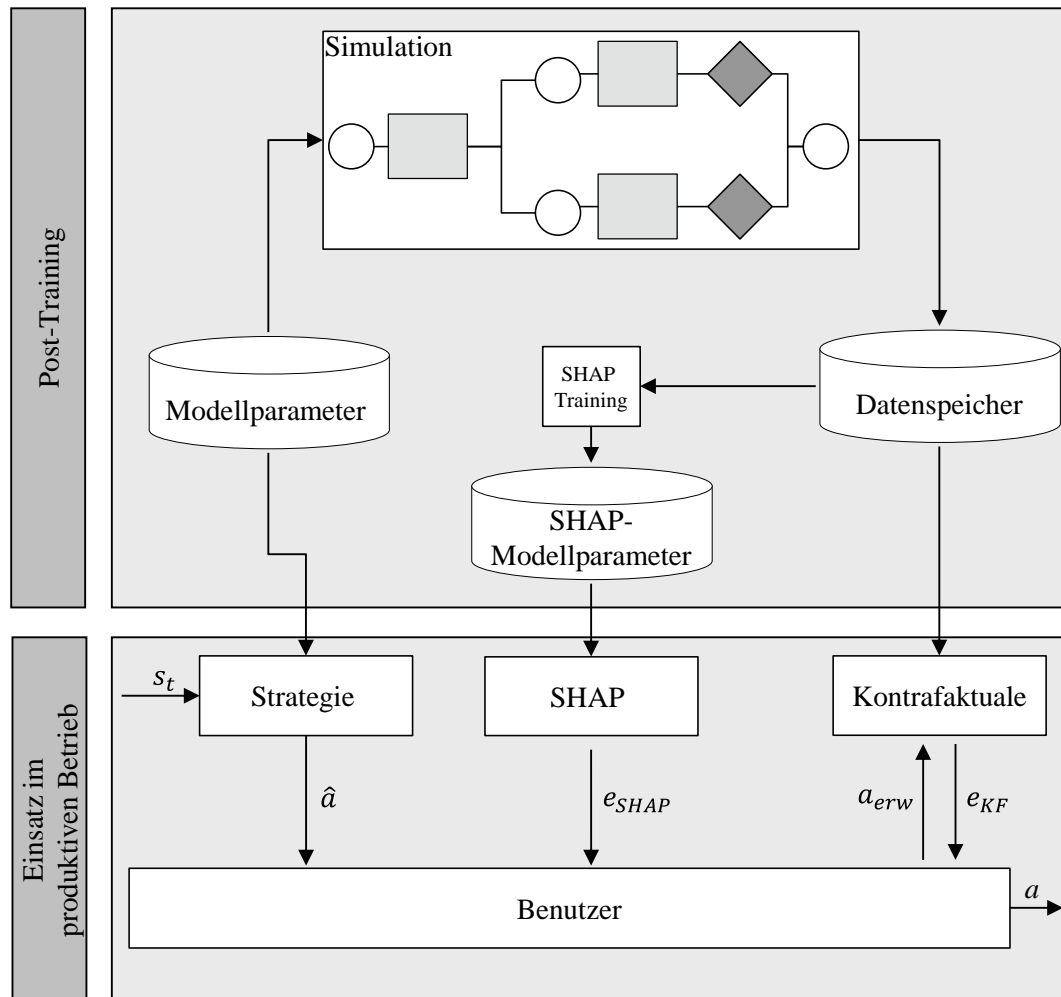


Abbildung 6-10: Beispielhafte Abbildung der Rechenzeit unterschiedlicher Erklärbarkeitsansätze in Abhängigkeit von der Anzahl der Merkmale

Damit die Integration der Erklärbarkeit in das lernende System gelingt, gilt es die anfallenden Daten strukturiert zu erfassen. Dies bildet die Basis für die Erklärbarkeitsverfahren. Die Daten, welche für das Surrogatmodell notwendig sind, bestehen aus dem Zustandsraum des Agenten sowie den daraus resultierenden Entscheidungen desselben.

Abbildung 6-11 beschreibt die Interaktionen zwischen Nutzern und dem System zur Entscheidungsunterstützung mit dem Fokus auf dem Einsatz von XAI. Damit die XAI-Methoden eingesetzt werden können, bedarf es einerseits eines trainierten Modells und andererseits Daten, welche das Verhalten des Systems sowie die daraufhin getroffenen Systementscheidungen repräsentieren. Für den Einsatz des Moduls zur Erklärbarkeit gilt es zwischen dem realen Einsatz und dem vorherigen Zeitraum – allerdings *Post-Training* – zu unterscheiden. Damit ein Einsatz möglich ist, gilt es die Daten in einer geeigneten Form abzuspeichern. Die Daten bestehen hierbei aus Beobachtungen, den Handlungsempfehlungen des Agenten und dem trainierten KNN. Diese Daten bilden wiederum die Grundlage für die Berechnung der SHAP-Werte. Im produktiven Betrieb erhält das SHAP-Modell die aktuelle Beobachtung sowie die zugehörige Aktionswahl des Agenten. Durch diese drei Bestandteile (Beobachtungen, Handlungsempfehlung und trainiertes KNN) ist die Bestimmung der Merkmalsrelevanz möglich.

Für die Berechnung der Kontrafaktuale sind entsprechend Formel (9) die aktuelle Beobachtung, die zugehörige Aktionswahl, die trainierte Strategie des Agenten sowie optional die vom Mitarbeiter erwartete Maßnahme notwendig. Basierend auf diesen Eingangsdaten wird die Optimierungsaufgabe gelöst und der Nutzer erhält ein bzw. mehrere Kontrafaktuale.



Legende:

\hat{a} : Entscheidungsvorschlag

a_{erw} : vom Nutzer erwarteter
Entscheidungsvorschlag

e_{KF} : Kontrafaktual

e_{SHAP} : Merkmalsrelevanz

s_t : Beobachtung

a : vom Nutzer
gewählte Aktion

Abbildung 6-11: Interaktion zwischen dem Nutzer und dem System zur Entscheidungsunterstützung (i. A. an HÖRMANN 2022)

Im Einsatz erhalten die Nutzer entsprechend der ausgewählten Unterstützungskategorie unterschiedliche Rückmeldungen vom System. In den Kategorien II und III wird ihnen basierend auf dem aktuellen Zustand des Systems (s_t) eine Aktion (\hat{a}) vorgeschlagen. Für die Entscheidungsunterstützung der Kategorie IV können sowohl Kontrafaktuale als auch die Merkmalsrelevanz berechnet werden. Zur Berechnung der Kontrafaktuale wird neben s_t auch \hat{a} als Input verwendet. Weiterhin wird die vom Nutzer erwartete Aktion (a_{erw}) bei der Berechnung berücksichtigt. Zusätzlich wird zum Einbezug der Datenverteilung für die Berechnung der

Kontrafaktuale auf den Hintergrunddatensatz zugegriffen. Unter Verwendung dieser Eingangsgrößen erfolgt die Berechnung der Kontrafaktuale, welche anschließend in Form einer textuellen Beschreibung an den Nutzer zurückgegeben werden können. Für die Generierung von Erklärungen mittels SHAP ist es notwendig, die SHAP-Werte zu berechnen. Hierfür ist ein Datensatz erforderlich, welcher historische Daten enthält. Unter Verwendung dieses Datensatzes erfolgt die Parametrierung des Surrogatmodells, welches die Bestimmung der Merkmalsrelevanz für einzelne Entscheidungen sowie für die allgemeine Verhaltensweise des Modells ermöglicht.

6.5 Fazit

In diesem Kapitel standen die Konzeptionierung und das methodische Vorgehen zur Realisierung der in Kapitel 4 definierten Kategorien IV und V der Entscheidungsunterstützung im Vordergrund. Ziel war es, insbesondere die dem System 2 inhärenten Bias zu mildern. Hierzu wurde zuerst die Integration von Erklärungen in den Entscheidungsprozess definiert und daraus Anforderungen an die Erklärungen abgeleitet. Anschließend wurden die unterschiedlichen Methoden der Erklärbarkeit klassifiziert und anhand der definierten Anforderungen bewertet. Zur Realisierung sowohl der lokalen als auch der globalen Erklärbarkeit wurde ein Verfahren zur Bestimmung der Merkmalsrelevanz ausgewählt. Als zweites Verfahren diente die Generierung von Kontrafaktualen. Charakteristisch für diese ist die kontrastive Natur der erzeugten Erklärungen. Abschließend konnte aufgezeigt werden, welche methodischen Schritte notwendig sind, um die Erklärungen in das lernende Agentensystem zu integrieren. Auf dieser Basis ergibt sich das lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung. Dieses Kapitel bildet den Abschluss der Präskriptiven Studie. Die Kapitel 3 bis 6 beschreiben das entwickelte lernende und erklärbare System zur Entscheidungsunterstützung. In den folgenden Kapiteln gilt es den Nachweis der prinzipiellen Funktionsfähigkeit zu erbringen.

7 Technische Umsetzung

7.1 Allgemeines

Die zweite Deskriptive Studie der DRM bildet den Abschluss der vorliegenden Arbeit. Sie hat das Ziel die prinzipielle Funktionsfähigkeit des entwickelten Systems nachzuweisen und zu bewerten. Der Nachweis und die Bewertung umfassen die Kapitel 7, 8 und 9. In Kapitel 7 erfolgt der Nachweis der Funktionsfähigkeit des entwickelten Systems am Beispiel eines realen Produktionssystems. Darauf folgend wird die Bewertung des Systems in Kapitel 8 vorgenommen. Abschließend werden die wichtigsten Erkenntnisse der vorliegenden Arbeit zusammengefasst.

Zum Nachweis der prinzipiellen Funktionsfähigkeit erfolgt in Kapitel 7 zuerst die Beschreibung des betrachteten Produktionssystems (siehe Abschnitt 7.2). Anschließend wird in Abschnitt 7.3 die Anwendung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung beschrieben. In Abschnitt 7.4 werden unterschiedliche Simulationsszenarien zur Bewertung des Systems definiert. Zum Abschluss erfolgen die simulationsbasierte Untersuchung der definierten Szenarien und deren Bewertung (siehe Abschnitt 7.4.3).

7.2 Beschreibung des betrachteten Produktionssystems

Die prototypische Erstellung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung erfolgte am Beispiel eines Lebensmittelproduzenten. Dem Produktionssystem liegt eine kundenauftragsorientierte Herstellung variantenreicher Schmelzkäseprodukte zugrunde. Im Anwendungsfall wurde die Produktion von 50 Rezepturen betrachtet. Aus diesen 50 Rezepturen werden 247 Artikel gefertigt. Unterschiedliche Artikel aus einer identischen Rezeptur kennzeichnen sich durch variierende Formatgrößen.

In Abbildung 7-1 ist der Produktionsprozess für die Herstellung der Schmelzkäseprodukte aufgezeigt. Er besteht aus den Stufen *Rohwarenannahme*, *Rohwarenvorbereitung*, *Mischen*, *Schmelzen*, *Endrezepturherstellung*, *Abfüllen*, *Kartонieren* und *Versand*. Im Rahmen dieser Arbeit liegt der Fokus auf den Produktionsschritten von Mischen bis Abfüllen. Während der Produktion der Schmelzkäseprodukte

können unerwünschte Nebenprodukte – sog. Rework und K3-Ware – entstehen. Rework entsteht während der Produktion durch Umstellprozesse, Zwischen- und Grundreinigungen sowie Störungen. Unter Berücksichtigung bestimmter Voraussetzungen (z. B. Haltbarkeit des Reworks, einwandfreie Qualität) kann das Nebenprodukt zu einem gewissen Bestandteil wieder in den Produktionsprozess zurückgeführt werden. Wie groß der Anteil der in den Prozess zurückgeführten Menge an Rework ist, wird durch rezepturspezifische Grenzwerte geregelt.

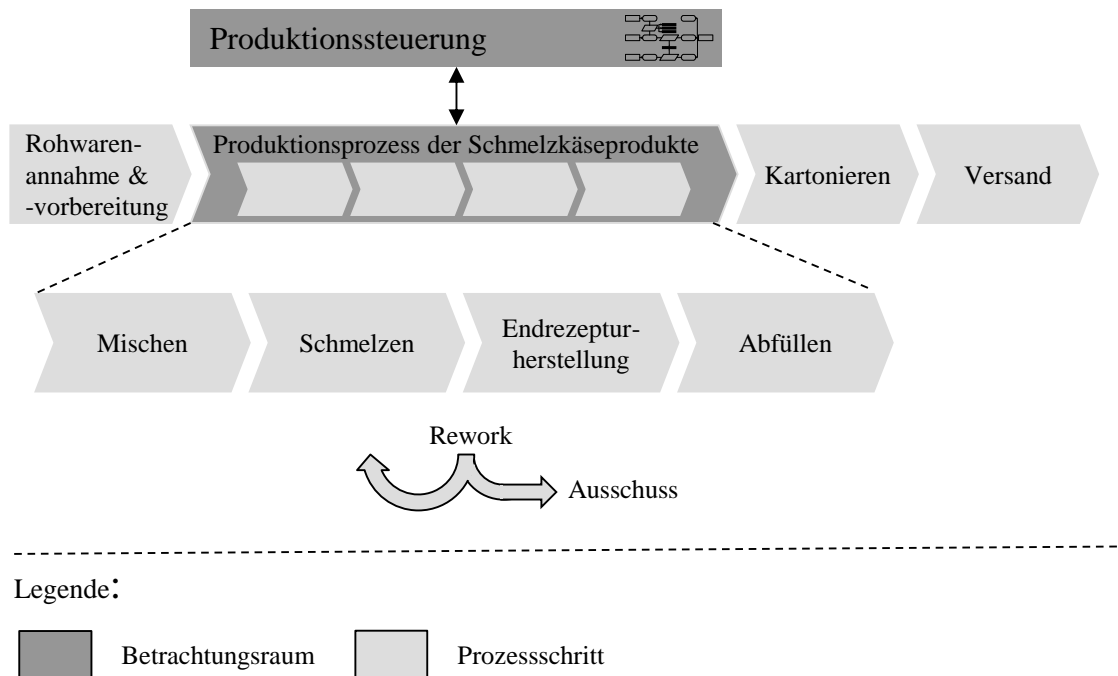


Abbildung 7-1: Abbildung des Produktionsprozesses inkl. Systemgrenze

Einen signifikanten Einfluss auf den Produktionsablauf hat die Auftragsreihenfolge. Entsprechend den Charakteristika der Produkte (z. B. ohne Gentechnik, allergenhaltig) gilt es unterschiedliche Anforderungen an die Reinigung zu erfüllen. Wird bspw. ein allergenhaltiger Artikel produziert, ist eine zeitintensive Grundreinigung notwendig, bevor ein Artikel ohne Allergene produziert werden kann. Tabelle 7-1 zeigt exemplarisch den Einfluss der Artikelreihenfolge auf die notwendigen Reinigungszeiten. Dies wird am Beispiel der Fertigungsreihenfolge zweier Artikel veranschaulicht. Bei einem Artikel handelt es sich um ein *Standardprodukt* (Produkt A), wohingegen es sich beim zweiten Artikel um ein Produkt handelt, welches die Zertifizierung *ohne Gentechnik* (Produkt B) besitzt. Im Szenario 1 wird zuerst das Produkt A gefertigt und anschließend auf derselben Anlage das Produkt B. Aufgrund der Anforderungen von Produkt B muss eine zeitintensive Reinigung durchgeführt werden. Wird allerdings, wie in Szenario 2 verdeutlicht,

zuerst das Produkt B und anschließend das Produkt A gefertigt, so ist die Dauer der notwendigen Reinigung deutlich kürzer. Zusätzlich zu den Reinigungszeiten fallen Rüstzeiten für den Wechsel der Verpackungsformate an.

Tabelle 7-1: Exemplarische Verdeutlichung des Einflusses der Artikelreihenfolge auf die notwendigen Reinigungszeiten

	Szenario 1	Szenario 2
Fertigungsreihenfolge	1. Produkt A 2. Produkt B	1. Produkt B 2. Produkt A
Resultierende Reinigungszeit zwischen A und B bzw. B und A	480 min	30 min

7.2.1 Produktionssystem

Das Produktionssystem des Anwendungspartners besteht aus zwei Linien (siehe Abbildung 7-2), jede Linie aus mindestens einer Anlage für den jeweiligen Prozessschritt. Allerdings können innerhalb einer Linie mehrere Parallelanlagen für den gleichen Prozessschritt vorhanden sein. Eine Produktionslinie besteht somit aus einer Kombination von Mischern, Schmelzanlagen, Anlagen zur Herstellung der Endrezeptur sowie Abfüllanlagen. Insgesamt wurden im untersuchten Anwendungsfall 26 Anlagen berücksichtigt. Zwischen den Anlagen existieren Puffer sowie Verbindungen, welche es erlauben, ausgehend von derselben Anlage unterschiedliche Produkte zu unterschiedlichen Anlagen der nachfolgenden Produktionsstufe zu leiten. Die Mitarbeiter arbeiten in einem Dreischichtmodell von Sonntagabend bis Freitagabend. In Ausnahmefällen ist eine zusätzliche Schicht am Samstag möglich. Treten unvorhergesehene Ereignisse ein, so ist eine Anpassung des Produktionsfeinplans zum Erreichen der logistischen Zielgrößen notwendig. Am Ende jeder Produktionswoche erfolgt die vollständige Reinigung des Produktionssystems.

Einzelne Anlagen können sich hinsichtlich der Produkte unterscheiden, welche durch sie gefertigt werden können. Zusätzlich können die Bearbeitungszeiten der Artikel in Abhängigkeit von der gewählten Anlage variieren. Die Merkmale des Produktionssystems sind in Tabelle 7-2 aufgeführt.

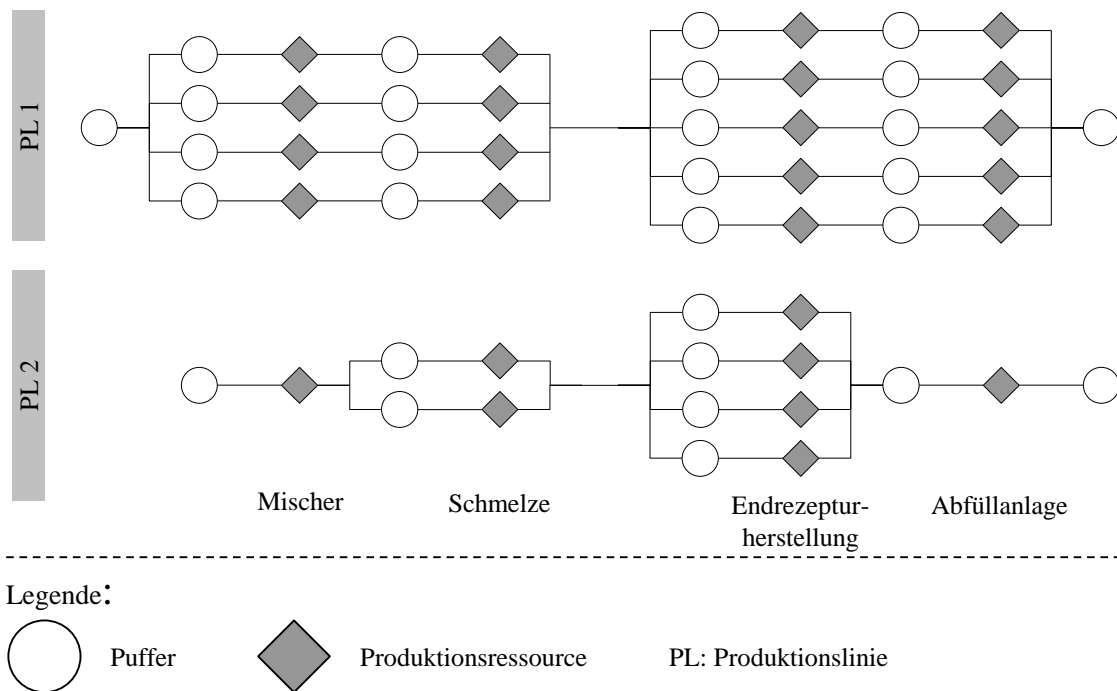


Abbildung 7-2: Abbildung der betrachteten Produktionslinien

Die Aufträge sind eindeutig durch eine Auftragsnummer identifizierbar. Weiterhin beinhaltet ein Auftrag die Rezeptur, die Artikelnummer, das Fertigstellungsdatum und die zu produzierende Menge. Aus der Rezeptur des Auftrags sowie der Rezeptur des Vorgängerauftrags ergeben sich die notwendigen Reinigungszeiten einer Anlage, bevor der betrachtete Auftrag gefertigt werden kann. Die Artikelnummer beeinflusst maßgeblich die notwendigen Rüstzeiten einer Anlage, bspw. durch unterschiedliche Verpackungsformate.

Im Produktionssystem können unvorhergesehene Ereignisse unterschiedlicher Art auftreten, welche den erfolgreichen Produktionsablauf stark beeinflussen. Einerseits können das durch Anlagenausfälle verursachte Störungen sein, andererseits kann es sich um Eilaufträge von strategisch relevanten Partnern handeln, welche es zu priorisieren gilt. Damit trotz dieser internen und externen Störfaktoren eine hohe logistische Leistungsfähigkeit erreicht werden kann, müssen geeignete Reaktionen im Rahmen der Produktionssteuerung erfolgen.

Tabelle 7-2: Parameter des Produktionssystems

	Parameter	Wertebereich
Produktionssystem	Anzahl der Anlagen	26
Aufträge	Anzahl an Rezepturen	50
	Anzahl an Artikeln	247
	Anteil Eilaufträge	10 %
Störungen	Wahrscheinlichkeit, dass eine Störung auftritt	0,01 %
	Dauer	60 min ($\sigma = 10$ min)

7.2.2 Aktueller Ablauf der Produktionssteuerung

Basierend auf den prognostizierten Kundenbedarfen sowie abgestimmten Sonderaktionen wird eine vierwöchige Vertriebsplanung erstellt. Davon ausgehend wird rollierend auf Wochenbasis ein Gesamtabsatzplan entworfen. Dieser wiederum bildet die Grundlage für den Grobplan. Allerdings wird der Grobplan ohne Berücksichtigung von Rückmeldedaten aus der Produktion erstellt, sodass die verfügbaren Kapazitäten und vorhandenes Rework darin nicht berücksichtigt werden.

Der nächste Schritt dient der Erstellung des Produktionsfeinplans. Diese erfolgt überwiegend manuell und beinhaltet die Planung der Produktionsaufträge auf unterschiedliche Produktionsressourcen unter Berücksichtigung der verfügbaren Kapazitäten. Die Reihenfolgebildung erfolgt anhand definierter Prioritätskennzahlen. Das Ergebnis ist der Produktionsfeinplan, welcher die Zuordnung zu spezifischen Produktionsressourcen sowie die Reihenfolge der zu fertigenden Produkte regelt. Treten unvorhergesehene Ereignisse auf, so erfolgt eine manuelle Anpassung des Produktionsfeinplans. In Abhängigkeit von den Auswirkungen erfolgt die Initiierung der Maßnahmen (z. B. Kapazitätsanpassung, Reihenfolgeoptimierung) ausgehend von unterschiedlichen Benutzern und dadurch von unterschiedlichen Hierarchieebenen.

7.2.3 Herausforderung

Eine zentrale Herausforderung für die Produktionssteuerung des Anwendungspartners liegt sowohl in der Reihenfolgebildung als auch in der Kapazitätssteuerung.

Durch die hohe Variantenvielfalt sowie den mehrstufigen Produktionsprozess ist die Erstellung des Produktionsfeinplans von einer hohen Komplexität gekennzeichnet. Die unterschiedlichen Produktvarianten können unterschiedlichen Kategorien (z. B. Standardprodukt, ohne Gentechnik) zugeordnet werden. Entsprechend den Kategorien unterscheiden sich die Anforderungen an notwendige Reinigungsprozesse. Aufgrund der Abhängigkeit der Rüst- und Reinigungszeiten vom Vorprodukt (siehe Abschnitt 7.2.3) hat die Reihenfolgebildung als Aufgabe der Produktionssteuerung einen signifikanten Einfluss auf die Leistungsfähigkeit der Produktion. Weiterhin gilt es, die unterschiedlichen Anlagen unter Berücksichtigung der Rüst- und Reinigungszeiten gleichmäßig auszulasten.

Tritt ein unvorhergesehenes Ereignis während des Produktionsablaufs auf, ist eine Reaktion darauf erforderlich. In Abhängigkeit von der voraussichtlichen Auswirkungsdauer des Ereignisses kann eine kurzfristige Umplanung der Aufträge notwendig sein. Die Anpassung des Produktionsfeinplans kann sowohl für Teilsysteme als auch für das Gesamtsystem erforderlich sein. Hierbei gilt es die oben aufgeführten Randbedingungen zu berücksichtigen. Die am häufigsten auftretenden unvorhergesehenen Ereignisse im Anwendungsfall sind Maschinenstörungen und Eilaufträge. Eilaufträge von Premiumkunden bergen eine besondere Herausforderung, da sie unter der Woche mit einem erwarteten Liefertermin in derselben Woche auftreten können.

Perspektivisch wird die vorhandene Komplexität weiter steigen, da beim Anwendungspartner ein Trend zu steigender Variantenvielfalt bei gleichzeitig kleiner werdenden Losgrößen erkennbar ist. Hierdurch nimmt der prozentuale Anteil der Rüst- und Reinigungszeiten an der gesamten Produktionszeit zu. Gleichzeitig wird es durch die steigende Komplexität für die Mitarbeiter schwieriger, die Auswirkungen von sowohl Steuerungsmaßnahmen als auch unvorhergesehenen Ereignissen auf das Gesamtsystem abzuschätzen. Zur Erreichung einer hohen Logistikleistung bei geringen Logistikkosten steigt somit die Bedeutung der Produktionssteuerung.

7.3 Anwendung des lernenden und erklärbaren Systems zur Produktionssteuerung

7.3.1 Allgemeines

Im folgenden Abschnitt erfolgt die Anwendung des lernenden und erklärbaren Systems zur Produktionssteuerung anhand des beschriebenen Anwendungsfalls. Hierfür erfolgte im ersten Schritt die Erstellung eines unternehmensspezifischen, benutzerrollenspezifischen Informationsmodells (siehe Abschnitt 7.3.2). Abschnitt 7.3.3 beschreibt den Aufbau des lernenden Systems zur Entscheidungsunterstützung unter Berücksichtigung des Informationsmodells. Weiterhin wurden die ausgewählten Erklärbarkeitsansätze in das lernende System zur Vervollständigung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung integriert.

Damit das entwickelte System in der Anwendung möglichst effektiv und effizient eingesetzt werden kann, müssen die unterschiedlichen Schritte zur Systemerstellung mit unterschiedlicher Wiederholhäufigkeit ausgeführt werden (siehe Abbildung 7-3). Prinzipiell kann eine Differenzierung in eine wiederholte Anwendung im Bedarfsfall und eine kontinuierliche Anwendung erfolgen.

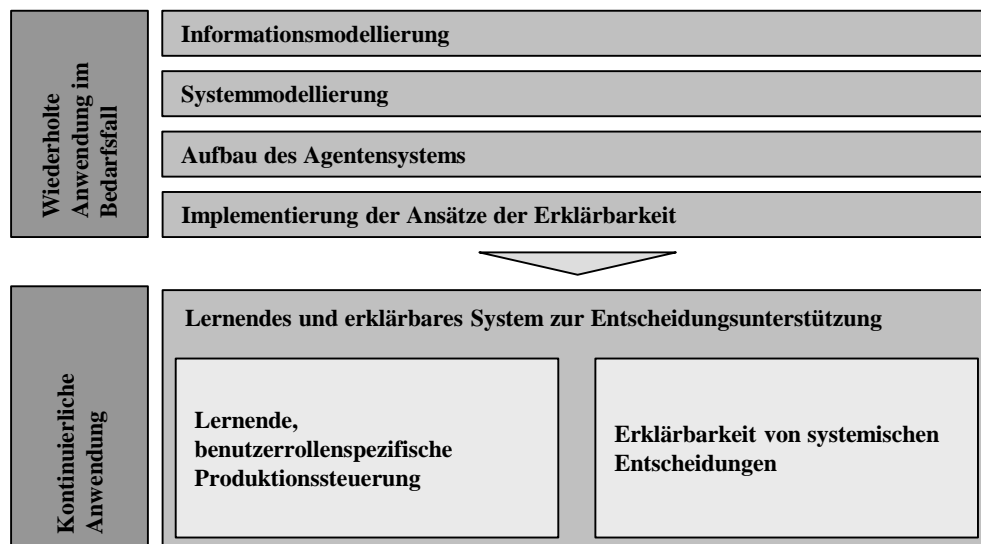


Abbildung 7-3: Differenzierung der unterschiedlichen Schritte zur Systemerstellung in Abhängigkeit von der Häufigkeit der Anwendung

7.3.2 Erstellen des unternehmens- und benutzerrollenspezifischen Informationsmodells

Im Rahmen der vorliegenden Arbeit wurden unterschiedliche Benutzerrollen betrachtet. Ausgehend vom entwickelten morphologischen Kasten (siehe Abbildung 7-4) erfolgte gemeinsam mit den Experten des Unternehmens die Identifizierung der an der Produktionssteuerung beteiligten Benutzer bzw. Benutzerrollen. Anschließend galt es im Rahmen von Expertenworkshops gemeinsam mit den identifizierten Benutzern die Charakteristika und Aufgaben der Produktionssteuerung der jeweiligen Benutzer strukturiert zu erfassen. Bei den identifizierten relevanten Akteuren für die Produktionssteuerung handelt es sich um den Produktionssteuerer, den Meister sowie den Anlagenbediener. Im Folgenden werden beispielhaft die Benutzerrollen *Meister* und *Anlagenbediener* beschrieben.

Unternehmensspezifische Anpassung des Referenzmodells

Anhand des erstellten morphologischen Kastens erfolgte die Charakterisierung des Benutzers *Meister*. Dieser ist der Aggregationsebene *Zelle* zugeordnet. Dort findet der Großteil seiner Tätigkeiten statt. Zum Erfüllen seiner Aufgaben sind sowohl Informationen von der gleichen Aggregationsstufe (z. B. Meister einer anderen Produktionslinie) als auch Informationen von anderen Aggregationsebenen (z. B. Zustand der Produktionsressourcen) relevant. Somit kann sein Betrachtungsraum als hybrid beschrieben werden. Das Tätigkeitsprofil ist überwiegend durch dispositive Arbeiten charakterisiert.

Benutzerrolle	Produktionsleiter	Produktionsplaner	Produktionssteuerer	Meister	Anlagenbediener
Aggregationsebene	Fabrik	Segment	System	Zelle	Arbeitsstation
Betrachtungsraum	Vertikal	Horizontal		Hybrid	
Tätigkeitsprofil	Operativ	Dispositiv		Hybrid	

Abbildung 7-4: Morphologischer Kasten für unterschiedliche Benutzerrollen sowie deren unterschiedliche Ausprägungen. Die Merkmale des Meisters sind hervorgehoben.

Der Benutzer *Anlagenbediener* wurde der Aggregationsebene *Arbeitsstation* zugeordnet. Die relevanten Informationen, welche er für Entscheidungen im Kontext der Produktionssteuerung benötigt, stammen von der Aggregationsebene, welcher

er selbst angehört. Einen Großteil der relevanten Informationen (z. B. zuletzt gefertigtes Produkt) stammt vom Arbeitssystem, welchem er zugeordnet ist. Das Tätigkeitsprofil ist fast ausschließlich operativ. In Tabelle 7-3 erfolgt beispielhaft die Beschreibung von Maßnahmen, welche die Benutzerrollen *Meister* und *Anlagenbediener* im Rahmen der Produktionssteuerung auslösen können.

Tabelle 7-3: Beispielhafte Beschreibung der relevanten Maßnahmen der identifizierten Benutzerrollen im Kontext der Produktionssteuerung

Benutzerrolle	Aufgabe der Produktionssteuerung	Maßnahme	Beschreibung
Meister	Auftragsfreigabe	Veränderung der Intensität des Ist-Zugangs	Durch die Einplanung von freigegebenen Aufträgen, basierend auf einer spezifischen Anlage unter Berücksichtigung berechneter Kapazitäten zum Ist-Zeitpunkt an der jeweiligen Anlage, kann auf den aktuellen Zustand im Produktionssystem reagiert werden.
	Reihenfolgebildung	Veränderung der Ist-Reihenfolge	Initiales Festlegen der Ist-Reihenfolge der den Anlagen zugeordneten Aufträge unter Berücksichtigung der resultierenden Reinigungszeiten.
Anlagenbediener	Reihenfolgebildung	Veränderung der Ist-Reihenfolge	Festlegen der Ist-Reihenfolge der Produktion unter Berücksichtigung der Rüst- und Reinigungszeiten.

Der initiale Unterstützungsbedarf sowohl für den Meister als auch den Anlagenbediener wurde mit der Kategorie II – Entscheidungsvorschlag ohne Zusatzinformationen – festgelegt. Zu betonen ist, dass es sich hierbei ausschließlich um eine

initiale Einordnung handelt. Im Bedarfsfall kann die gewünschte Unterstützungskategorie gewechselt und somit eine individuelle Anpassung vorgenommen werden.

Die wesentlichen Bestandteile (Benutzerrolle, Maßnahmenkatalog und Kategorien der Entscheidungsunterstützung) wurden somit definiert. Die identifizierten Benutzerrollen inklusive der zugehörigen Szenarien bilden die Grundlage für die technische Umsetzung in den folgenden Abschnitten.

7.3.3 Technische Umsetzung

7.3.3.1 Softwaretechnische Umsetzung

Für die prototypische Umsetzung des lernenden und erklärbaren Systems wurden unterschiedliche Module implementiert (siehe Abbildung 7-5). Das Produktionsprogramm diente als Input für die Simulationsumgebung des Produktionssystems. Der Aufbau der Simulationsumgebung folgte den Richtlinien von *OpenAI Gym*. Die Simulation selbst wurde in *Python* geschrieben und beinhaltet die für den Produktionsablauf relevanten Ressourcen. Zur Implementierung des Agentensystems wurde das *Framework RLlib* verwendet. RLlib bietet die grundlegende Infrastruktur zur Parallelisierung des Lernvorgangs der Agenten, wodurch der Lernprozess beschleunigt wird (LIANG ET AL. 2018). Für das Training des DRL-Algorithmus wurde *TensorFlow* genutzt. Im Rahmen der Implementierung der Erklärbarkeit wurden zwei unterschiedliche Bibliotheken verwendet. Die Berechnung der Merkmalsrelevanz erfolgte mit Hilfe von SHAP (LUNDBERG & LEE 2017). Für die Generierung der Kontrafaktuale wurde die Bibliothek *Diverse Counterfactual Explanations* (DiCE) herangezogen (MOTHILAL ET AL. 2020). Die Kontrolle des Lernverhaltens der Agenten anhand unterschiedlicher Metriken (z. B. Belohnung) erfolgte mit Hilfe von *TensorBoard*. Hierbei handelt es sich um eine webbasierte Visualisierungsapplikation. Der resultierende Produktionsfeinplan wurde in einer eigens entwickelten webbasierten Visualisierungsoberfläche dargestellt. Diese ermöglichte es, unterschiedliche Kennzahlen, den Aufbau des Produktionssystems sowie die unterschiedlichen Produktionszustände zu betrachten.

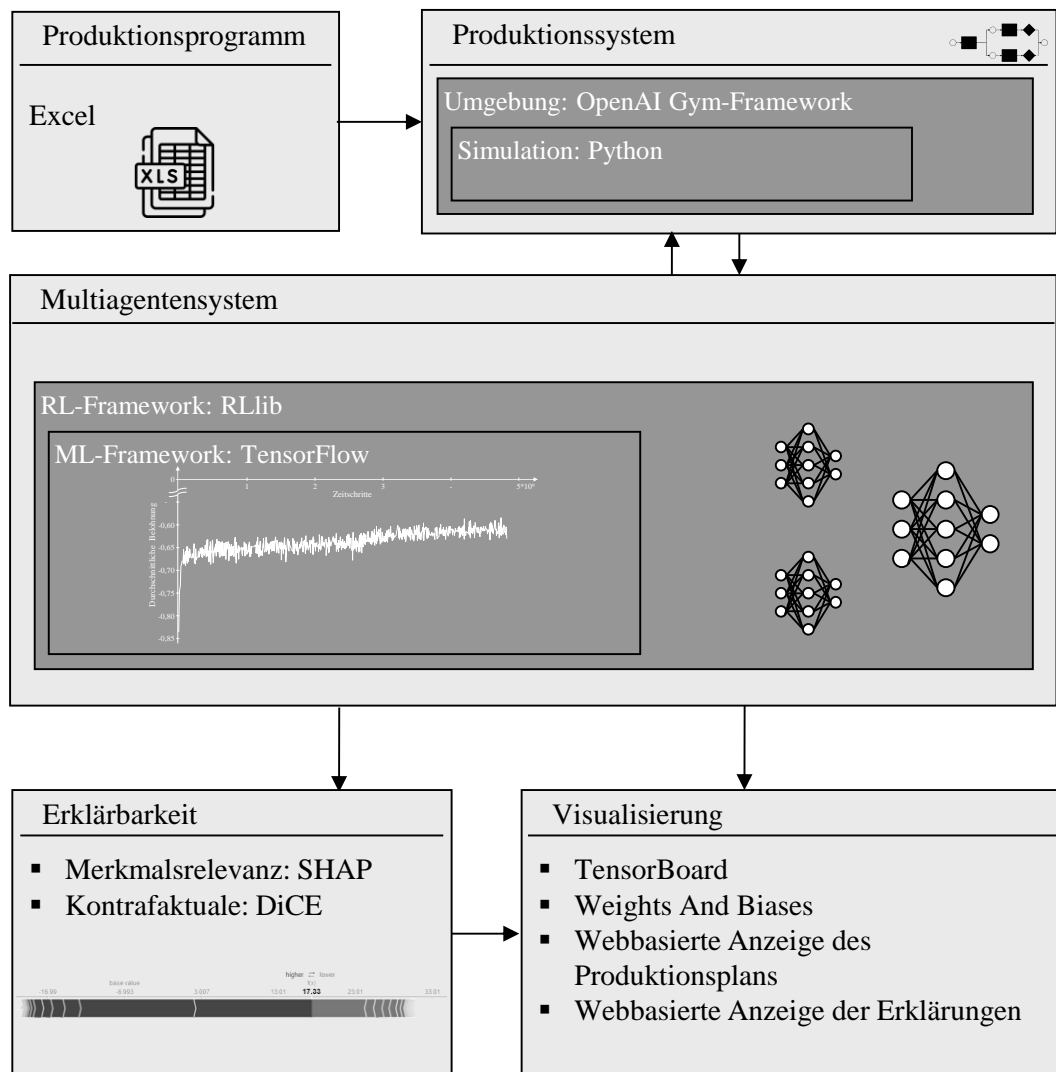


Abbildung 7-5: Softwareübersicht des entwickelten Systems

7.3.3.2 Erstellung der lernenden Produktionssteuerung

Identifikation relevanter Agententypen

Als Ausgangspunkt der relevanten Agententypen dienten die in Abschnitt 7.3.2 definierten, für die Durchführung der Aufgaben der Produktionssteuerung relevanten, Benutzerrollen. Aus diesen Benutzerrollen wurden Agententypen abgeleitet. Für jede Benutzerrolle wurde mindestens ein Agententyp erstellt. Im vorliegenden Fall wurden Agententypen für die Benutzerrollen *Produktionssteuerer*, *Meister* sowie *Anlagenbediener* erstellt (siehe Tabelle 7-4). Im Folgenden wird die Ableitung

und Implementierung der spezifischen Agenten basierend auf den Benutzerrollen beschrieben.

Tabelle 7-4: Übersicht über die notwendigen Agenten für das Gesamtsystem


Aggregationsebene	Agententyp	Anzahl
System	Produktionssteuereragent	1
Zelle (Produktionslinie 1)	Meisteragent	2
Arbeitsstation	Anlagenbedieneragent	18
Zelle (Produktionslinie 2)	Meisteragent	2
Arbeitsstation	Anlagenbedieneragent	8

Ableitung und Implementierung spezifischer Agenten

Grundlegend für die Ableitung und Implementierung der spezifischen Agenten war das in Abschnitt 5.5 erstellte Template. Zur Ableitung der Agenten wurde das Template für unterschiedliche Agenten in Anlehnung an die im Produktionssystem auftretenden relevanten Benutzerrollen ausgefüllt. Mit Hilfe der Agenten ist es möglich, unterschiedliche Benutzerrollen des Produktionssystems zielgerichtet in Entscheidungssituationen zu unterstützen. Bei der Unterstützung werden die individuellen Maßnahmen, welche im Rahmen der Produktionssteuerung durch die Mitarbeiter initiiert werden können, berücksichtigt. Der Aufbau des Agentensystems orientierte sich am organisatorischen Aufbau. Abbildung 7-6 zeigt den Aufbau des Agentensystems inklusive der jeweiligen Verantwortungsbereiche.

Beschreibung des Produktionssteuereragenten

Der Produktionssteuerer hat die Aufgabe, basierend auf dem Produktionsprogramm die Aufträge unter Berücksichtigung der verfügbaren Kapazitäten auf die einzelnen Produktionslinien zu verteilen. Bei der Festlegung der Ist-Kapazität gilt es neben den verfügbaren Kapazitäten die Anlagenfähigkeiten zu berücksichtigen. In der vorliegenden Arbeit erfolgte eine Verteilung der Aufträge zwischen den Produktionslinien. Prinzipiell können Aufträge auf verschiedene Art und Weise im Beobachtungsraum des Agenten repräsentiert werden (siehe Abschnitt 5.3.2). Aufgrund der Vielzahl unterschiedlicher Aufträge erfolgte für den beschriebenen Anwendungsfall eine Modellierung auf Klassensicht. Der Beobachtungsraum des



Legende:




Abbildung 7-6: Konzeptioneller Aufbau des Agentensystems unter Berücksichtigung der unterschiedlichen Aggregationsebenen des Produktionssystems

Agenten enthält somit die Anzahl der verfügbaren Aufträge der jeweiligen Kategorie sowie die aufsummierte Produktionszeit dieser Aufträge.

Beschreibung des Meisteragenten

Die Aufgabe des Meisteragenten ist es, einen Auftrag aus einem Eingangspuffer auf mehrere anlagenindividuelle Puffer zu verteilen. Ziel ist es, die Aufträge so zu verteilen, dass sowohl eine gleichmäßige Auslastung der Anlagen als auch eine möglichst geringe Durchlaufzeit der Aufträge realisiert werden kann. Abbildung 7-7 zeigt beispielhaft ein für den Meisteragenten der Produktionslinie 1 ausgefülltes Template. Für diesen erfolgte aufgrund der Vielzahl unterschiedlicher Aufträge und Produktionsressourcen, auf welche die Aufträge verteilt werden können, ebenfalls eine Modellierung der Aufträge in der Klassensicht. Diese resultierte in einem Beobachtungsraum, welcher die Anzahl der verfügbaren Aufträge der jeweiligen Kategorie und die aufsummierte Produktionszeit dieser Aufträge enthält. Im konkreten Anwendungsfall konnte für den Meisteragenten PL 1 die Dimension des Beobachtungsraums von 1240 Einträgen (Auftragssicht) auf 118 Einträge (Klassensicht) verringert werden. Die Bildung erfolgte mit Hilfe einer k-Means-Analyse

Allgemeine Informationen			
Name	Meister – PL 1		
Musterkategorie	Verbesserung der Auftragsfreigabe		
Agententyp	Meister	Benutzerrolle	Meister
Beschreibung	Der Meister – PL 1 hat die Aufgabe, für die Produktionslinie PL 1 die vorhandenen Aufträge unterschiedlichen Produktionsressourcen mit einer initialen Reihenfolge zuzuweisen.		
Anwendungsfall			
Kontext	Produktionssteuerung		
MAS-Architektur	Reaktiv		
Echtzeitfähigkeit	weich		
Maßnahmen	Kapazitätssteuerung, Festlegung der initialen Reihenfolge		
Zustandsraum und Aktionsraum			
Zustandsraum	Klassensicht, Informationen über den Zustand untergeordneter Ressourcen		
Aktionsraum	Zuteilen von Aufträgen		
Zeitpunkt des Agierens	Auftreten einer Störung sowie eines Eilauftrags		
Lernverhalten			
Wissensbasis	Künstliches neuronales Netz		
Lernen, Wissensakquise	DRL, PPO als Actor-Critic		
Kooperation	Implizit durch gemeinsames Training mit anderen Agenten		
Sonstiges			
Implementierung	OpenAI Gym, RLlib		

Abbildung 7-7: Ausgefülltes Template für den Agenten *Meister* der Produktionslinie 1


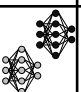

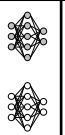

(siehe Anhang 14.3.1). Hierdurch konnte auch der Aktionsraum um 89 % verringert werden. Gleichzeitig konnte die Lösungsqualität, repräsentiert durch die entstehenden Kosten, erhöht sowie die Trainingsdauer reduziert werden.

Beschreibung des Anlagenbedieneragenten

Der Agent *Anlagenbediener* hat die Aufgabe, den nächsten Auftrag aus einer Warteschlange auszuwählen. Entsprechend dem gewählten Auftrag sowie in Abhängigkeit vom vorherigen Auftrag fallen unterschiedliche Rüst- und Reinigungszeiten an. Im Beobachtungsraum des Agenten sind die in der Warteschlange enthaltenen Aufträge repräsentiert. Außerdem erhält der Agent die erwartete Rüst- und Reinigungszeit für die spezifischen Aufträge im Beobachtungsraum. Durch die Auswahl des zu fertigenden Auftrags beeinflusst der Agent somit die resultierenden Rüst- und Reinigungszeiten.

Implementierung des DRL-Algorithmus

Für die Implementierung des DRL-Algorithmus PPO wurde auf die Bibliothek RLlib zurückgegriffen. Für das Training wurde der PPO-Algorithmus als Actor-Critic-Ansatz implementiert. Entsprechend Abschnitt 5.4.4 wurde ein mehrstufiger Trainingsablauf realisiert. Abbildung 7-8 zeigt anhand der Produktionslinie PL 1 die Gestaltung des Trainings. Das Training beinhaltet drei Stufen. Das initiale Training der Stufe I erfolgte mit zufällig initialisierten Gewichten für jeweils einen Agenten. Diese wurden während des Trainings kontinuierlich aktualisiert, bis das Konvergenzkriterium erfüllt war. Aufgrund divergierender Beobachtungs- und Aktionsräume galt es jeweils zwei Anlagenbedieneragenten und Meisteragenten zu trainieren. In Stufe II erfolgte die Initialisierung des Meisteragenten und der Anlagenbedieneragenten basierend auf vorhandenen Gewichten. Im vorliegenden Anwendungsfall wurden für die Produktionslinie PL 1 zwei unterschiedliche Gruppen trainiert, welche sich in Anlehnung an den Aufbau des Produktionssystems in der Anzahl der benötigten Agenten unterschieden. Im letzten Schritt (Stufe

	Agent(en)	Aktionen	Ziel	KNN
Stufe I	Unterschiedliche Anlagenbedieneragenten 	Auftrag auswählen	<ul style="list-style-type: none"> Reihenfolgeoptimierung Berücksichtigung unterschiedlicher Prioritäten 	Initialisierung mit zufälligen Gewichten
	Unterschiedliche Meisteragenten 	Auftrag zuweisen	<ul style="list-style-type: none"> Kapazitätssteuerung Berücksichtigung von Prioritäten 	Initialisierung mit zufälligen Gewichten
Stufe II	Ein Meisteragent Vier Anlagenbedieneragenten 	<ul style="list-style-type: none"> Auftrag zuweisen Auftrag auswählen 	<ul style="list-style-type: none"> Reihenfolgeoptimierung Berücksichtigung unterschiedlicher Prioritäten 	Initialisierung mit vortrainierten Gewichten aus Stufe I
	Ein Meisteragent Fünf Anlagenbedieneragenten 	<ul style="list-style-type: none"> Auftrag zuweisen Auftrag auswählen 	<ul style="list-style-type: none"> Kapazitätssteuerung Berücksichtigung von Prioritäten 	Initialisierung mit vortrainierten Gewichten aus Stufe I
Stufe III	Zwei Meisteragenten Neun Anlagenbedieneragenten 	<ul style="list-style-type: none"> Auftrag zuweisen Auftrag auswählen 	<ul style="list-style-type: none"> Reihenfolgeoptimierung Berücksichtigung unterschiedlicher Prioritäten 	Initialisierung mit vortrainierten Gewichten aus Stufe II

Legende:




Abbildung 7-8: Ablauf des Curriculum Learnings am Beispiel der Produktionslinie 1

III) wurden die in Stufe II erlernten Strategien der Agenten zur Initialisierung der Agenten am Anfang des Trainings verwendet. Im Rahmen dieser Stufe wurden alle Agenten gleichzeitig trainiert.

Auswirkungen unterschiedlicher Konfigurationen auf die Lösungsgüte

Durch die Abbildung der unterschiedlichen Benutzer als Agenten war die Realisierung eines hybriden Systemaufbaus möglich. Dies erlaubt eine benutzerspezifische Informationsdarstellung und erhöht gleichzeitig die Lösungsqualität gegenüber einem rein zentralen oder dezentralen System. Abbildung 7-9 zeigt die resultierende Lösungsqualität in Abhängigkeit von den unterschiedlichen Systemkonfigurationen für den konkreten Anwendungsfall. Bei den Szenarien I und II handelt es sich um zentrale Ansätze, bei denen der Meisteragent die Aufträge den unterschiedlichen Anlagen zuteilt. Die initiale Reihenfolge wurde durch eine Heuristik angepasst. In Szenario I kam die Heuristik FIFO und bei Szenario II die Heuristik Shortest Setup Time Next (SSTN) für die Festlegung der finalen Bearbeitungsreihenfolge zum Einsatz. Szenario III entspricht einer dezentralen Steuerung. Die Anlagenagenten wählten den nächsten zu fertigenden Auftrag aus einem Puffer aus und bestimmten dadurch den Ist-Zugang zur Anlage und die Ist-Reihenfolge. Bei Szenario IV handelt es sich um eine hybride Systemarchitektur. Der Meisteragent wies die ihm zur Verfügung stehenden Aufträge den einzelnen Anlagenagenten zu. Somit definierte er den Ist-Zugang sowie eine initiale Reihenfolge der Aufträge. Diese Reihenfolge konnte durch den Anlagenagenten optimiert und der nächste zu fertigende Auftrag ausgewählt werden. In den Simulationsversuchen




Abbildung 7-9: Entwicklung der OPP in Abhängigkeit vom Systemaufbau (i. A. an MAAG 2023)

hat sich gezeigt, dass für den vorliegenden Anwendungsfall eine hybride Systemarchitektur im Vergleich zur zentralen und dezentralen Systemarchitektur eine höhere Lösungsqualität – charakterisiert durch eine höhere OPP – liefert.

7.3.3.3 Resultierender Produktionsplan

Der durch das Agentensystem erstellte Produktionsplan (siehe Abbildung 7-10) zeigt die unterschiedlichen Zustände der Produktionsressourcen am Beispiel der Produktionslinie PL 1. Auf der x-Achse ist die Zeit und auf der y-Achse sind die unterschiedlichen Produktionsressourcen aufgetragen. Die unterschiedlichen Zustände der Anlagen (*Reinigen*, *Rüsten* und *Produzierend*) sind farblich codiert. Mit Hilfe der entwickelten webbasierten Visualisierung kann eine detaillierte Analyse des Produktionsplans und der zugehörigen Metriken erfolgen.




Abbildung 7-10: Visualisierung des resultierenden Produktionsplans für die Produktionslinie PL 1 mit Hilfe der entwickelten webbasierten Visualisierung

7.3.3.4 Integration der Erklärbarkeitsansätze

Dieser Abschnitt beschreibt die Realisierung der Kategorien IV und V der Entscheidungsunterstützung durch die Verwendung von Erklärbarkeitsansätzen. Zum Auflösen der Blackbox wurden ausgewählte Erklärbarkeitsansätze – die Bestimmung der Merkmalsrelevanz und die Berechnung der Kontrafaktuale – implementiert. Hierfür wurden die Open-Source-Bibliothek SHAP (LUNDBERG & LEE 2017) und DiCE (MOTHILAL ET AL. 2020) verwendet. Diese galt es in das lernende System zu integrieren. Unter Verwendung der für jeden Agenten spezifisch trainierten KNNs konnten agentenspezifische – und somit benutzerrollenspezifische – Erklärungen generiert werden.

Abbildung 7-11 zeigt beispielhaft die lokale Erklärung einer Entscheidung. Hierbei wird der additive Beitrag der SHAP-Werte der Merkmale zu einer einzelnen Entscheidung (Auswahl Rezeptur Kategorie R30) gezeigt. In Rot werden die Merkmale dargestellt, welche qualitativ zu einer Erhöhung der Wahrscheinlichkeit beitragen. Die Quantität des Beitrags wird durch die Größe des Balkens repräsentiert. In diesem konkreten Fall haben sich insbesondere die letzte Rezeptur (LO = R51) sowie die Tatsache, dass kein weiterer Auftrag der Rezeptur R51 vorhanden ist (O R51 = 0), positiv auf die Entscheidung ausgewirkt. In Blau sind hingegen diejenigen Merkmale zu sehen, welche die Wahrscheinlichkeit reduziert haben. Negativ ausgewirkt hat sich in diesem Beispiel, dass der letzte Auftrag nicht von der Rezeptur R30 war.

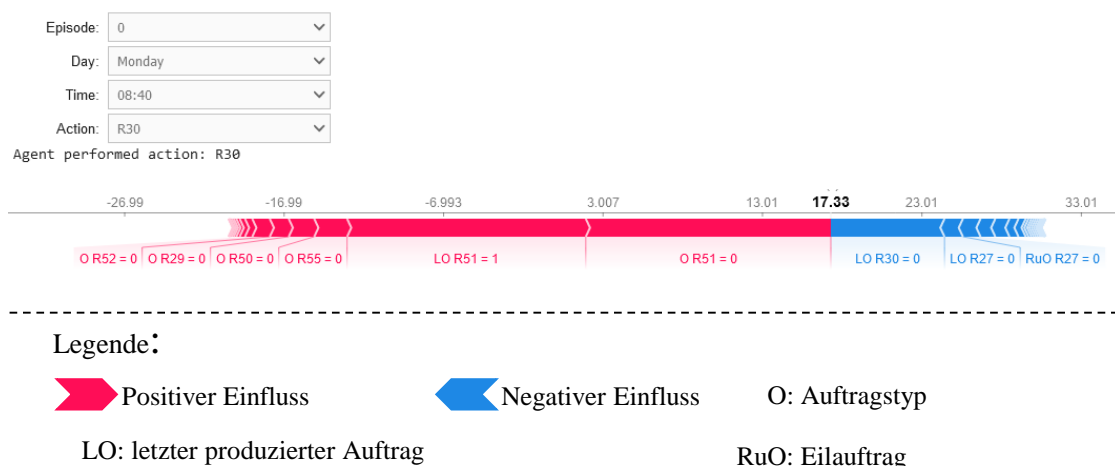


Abbildung 7-11: Veranschaulichung der Merkmalsrelevanz mit Hilfe von SHAP-Werten (i. A. an KRUSE 2023)

Kontrafaktuale	
Kontrafaktual 1	Wenn für die Produktionsressource 1.1.2 die Rezeptur R 52 vorgesehen und alle anderen Werte konstant gewesen wären, dann wäre die Rezeptur R 55 der Produktionsressource 1.1.2 anstatt der Produktionsressource 1.1.1 zugeordnet worden.
Kontrafaktual 2	Wenn für die Produktionsressource 1.1.2 die Rezeptur R 30 vorgesehen und alle anderen Werte konstant gewesen wären, dann wäre die Rezeptur R 55 der Produktionsressource 1.1.2 anstatt der Produktionsressource 1.1.1 zugeordnet worden.
Kontrafaktual 3	Wenn für die Produktionsressource 1.1.1 als nächste, zu produzierende Rezeptur die Rezeptur R 37 vorgesehen und alle anderen Werte konstant gewesen wären, dann wäre die Rezeptur 55 der Produktionsressource 1.1.2 anstatt der Produktionsressource 1.1.1 zugeordnet worden.

Abbildung 7-12: Ausgabe dreier unterschiedlicher Kontrafaktuale unter Berücksichtigung des vom Benutzer erwarteten Ergebnisses (Zuordnung der Rezeptur R55 zur Produktionsressource R 1.1.2)

Zum Ableiten von Aussagen ist bei der graphischen Ausgabe der SHAP-Werte eine Interpretationsleistung notwendig, wohingegen die textuelle Ausgabe der Kontrafaktuale diese nicht erfordert. Abbildung 7-12 zeigt drei unterschiedliche Kontrafaktuale. Die erwartete Handlungsempfehlung entspricht in diesem Fall der Zuordnung der Rezeptur R55 zur Produktionsressource 1.1.2. Die Kontrafaktuale beschreiben, welche Zustände sich verändern müssten, damit die erwartete Handlungsempfehlung ausgegeben worden wäre.

Durch die Umsetzung dieser beiden divergierenden Arten der lokalen Erklärung von Entscheidungen des Modells können Mitarbeiter gezielt unterstützt werden. Die globale Erklärbarkeit – und damit die generelle Funktionsweise des Modells – kann mit Hilfe aggregierter Merkmalsrelevanz bestimmt werden.

Abbildung 7-13 zeigt die Einflussfaktoren der Entscheidungen eines einzelnen Agenten. Es wird die statistische Verteilung der SHAP-Werte für eine ausgewählte Aktion gezeigt. Somit lassen sich Aussagen zum Einfluss einzelner Merkmale auf die Auswahl einer Aktion treffen. Im konkreten Fall – Auswahl der Rezeptur R30 – hat es betragsmäßig den größten Einfluss, ob der letzte produzierte Auftrag der Rezeptur R30 entsprochen hat. Weiterhin beeinflusst die Rezeptur R51 die Auswahl des Agenten. Dies zeigt sich einerseits in der Relevanz des Vorhandenseins der Rezeptur R51. Andererseits ist für die Auswahl der Rezeptur R30 ebenfalls wichtig, ob der letzte produzierte Auftrag die Rezeptur R51 war. Im Vergleich mit den anderen Merkmalen haben diese drei Merkmale den betragsmäßig größten




Abbildung 7-13: Abbildung der globalen Erklärbarkeit mit Hilfe der Visualisierung des betragsmäßigen durchschnittlichen Einflusses unterschiedlicher Merkmale auf die Auswahl einer bestimmten Aktion (Auswahl der Rezeptur R30) (i. A. an KRUSE 2023)

Einfluss auf die Entscheidung. Für ergänzende Abbildungen sei auf Anhang 14.3.2 verwiesen.

7.4 Simulationsbasierte Umsetzung

7.4.1 Simulationsszenarien

Tabelle 7-5 zeigt unterschiedliche Simulationsszenarien, welche im Rahmen dieser Arbeit untersucht und zur Bewertung des Systems herangezogen wurden. Insgesamt wurden sechs Simulationsexperimente durchgeführt. Diese unterscheiden sich hinsichtlich der zugrunde liegenden Logik der Produktionssteuerung sowie der Reihenfolgedisziplin bei der Ausführung des Produktionsplans.

Bei der Reihenfolgedisziplin handelt es sich um ein Maß, welches verwendet wird, um die Ausführungscompliance von vorgegebenen Reihenfolgen (z. B. basierend auf Heuristiken) zu quantifizieren. Es kann vorkommen, dass der verantwortliche Mitarbeiter aufgrund von sachfremden Kriterien von einer vorgegebenen Reihenfolge abweicht. Dies wiederum kann einen signifikanten Einfluss (z. B. aufgrund eines Materialflussabbrisses, ausgelöst durch ein fehlendes Vorprodukt) auf die Erreichung der logistischen Zielgrößen des Unternehmens haben.

Tabelle 7-5: Unterschiedliche Simulationsszenarien unter Berücksichtigung der Art der Produktionssteuerung, der Realisierung von Erklärbarkeit sowie der angenommenen Reihenfolgedisziplin

	Szenario					
	I	II	III	IV	V	VI
Regelbasierte Produktionssteuerung	●					
RL-basierte Produktionssteuerung		●	●	●	●	●
Ansätze der Erklärbarkeit					●	●
Reihenfolgedisziplin in %	100	80	85	90	95	100

In Abhängigkeit vom Unternehmen bzw. von unterschiedlichen Unternehmensbereichen kann die Reihenfolgedisziplin stark schwanken. In der Literatur (siehe KUYUMCU 2013, WASCHNECK 2020) liegen die angegebenen Werte der Reihenfolgedisziplin zwischen 25 % und 91 %. Im Falle der vorliegenden Simulationsstudien wurden für die Simulationsszenarien, welche ausschließlich einen Einsatz der lernenden benutzerrollenspezifischen Produktionssteuerung repräsentieren, Reihenfolgedisziplinen von 80 % bis 90 % angenommen. Durch die Realisierung der Erklärbarkeit von systemischen Entscheidungen kann SABMANNSHAUSEN (2019) folgend angenommen werden, dass die Akzeptanz der Lösungsvorschläge steigt. Diese Steigerung der Akzeptanz korrespondiert wiederum mit einer höheren Reihenfolgedisziplin. Dies spiegelt sich in den Szenarien V und VI wider.

Szenario I

Bei Szenario I handelt es sich um das Referenzszenario. Es bildet den Status quo des Schmelzkäseproduzenten ab und dient als Ausgangspunkt für die Bewertung der entwickelten Lösung. Der Feinplan wurde vor Beginn einer Produktionswoche unter Berücksichtigung der Bestellmengen und der vorhandenen Produktionskapazitäten erstellt. Die Reaktion auf unvorhergesehene Ereignisse erfolgte im Rahmen dieses Szenarios regelbasiert (FIFO). Aufgrund der menschlichen Ersteller des Produktionsfeinplans sowie der einfachen und transparenten Reaktion auf unvorhergesehene Ereignisse kann eine Reihenfolgedisziplin von 100 % angenommen werden.

Szenario II

Für das betrachtete Szenario II erfolgte sowohl die Feinplanerstellung als auch die Reaktion auf unvorhergesehene Ereignisse durch das Agentensystem mit DRL. Zum Anfang einer Produktionswoche wurde unter Berücksichtigung der zu fertigenden Aufträge der Feinplan erstellt. Trat ein unvorhergesehenes Ereignis ein, so erfolgte die Reaktion durch das Agentensystem unter Berücksichtigung der Rückmeldedaten. Bei Szenario II kam ausschließlich das lernende benutzerrollenspezifische System zum Einsatz, welches ein KNN zur Aktionswahl beinhaltet. Dies entspricht der Realisierung der Kategorien II und III der Entscheidungsunterstützung. Aufgrund des Einsatzes des Blackbox-Verfahrens wurde für dieses Szenario eine Reihenfolgedisziplin von 80 % angenommen.

Szenario III und IV

Szenario III und IV entsprechen in Bezug auf den prinzipiellen Aufbau Szenario II. Allerdings wurde für dieses Szenario eine Reihenfolgedisziplin von 85 % bzw. 90 % angenommen.

Szenario V

Analog zu den Szenarien II bis IV ist Szenario V durch die Erstellung des Feinplans durch das Agentensystem zu Beginn einer Woche gekennzeichnet. Die Reaktion auf unvorhergesehene Ereignisse erfolgte ebenfalls durch das Agentensystem. Im Rahmen dieses Szenarios wurde eine 95-prozentige Reihenfolgedisziplin angenommen. Dies ist dadurch gerechtfertigt, dass im Rahmen von Szenario V angenommen wurde, dass das lernende und erklärbare System zur Entscheidungsunterstützung eingesetzt wurde. Somit wurden in diesem Szenario die Kategorien II, III, IV und V der Entscheidungsunterstützung realisiert. Aufgrund der Erklärbarkeit der systemischen Entscheidungen steigt das Vertrauen der Mitarbeiter in das System und den Empfehlungen des Systems wird häufiger Folge geleistet.

Szenario VI

Szenario VI ist nahezu identisch mit Szenario V. Allerdings wird hierfür eine Reihenfolgedisziplin von 100 % angenommen.

7.4.2 Verifizierung des Simulationsmodells

Im Rahmen dieser Arbeit nimmt das Simulationsmodell eine zentrale Rolle ein. Einerseits diente es dem Training der Agenten und andererseits wurden mit Hilfe

des Simulationsmodells die definierten Experimente (siehe Abschnitt 7.4.1) durchgeführt und bewertet. Die systematische Verifizierung erfolgte anhand ausgewählter Verifizierungstechniken für die Simulation in Produktion und Logistik nach RABE ET AL. (2008) (siehe Tabelle 7-6).

Tabelle 7-6: Übersicht über ausgewählte Techniken zur Verifizierung von Simulationen in Produktion und Logistik

Verifizierungstechniken	Beschreibung
Ereignisvaliditätstest	Abgleich von in der Simulation auftretenden Ereignissen oder einer Abfolge von auftretenden Ereignissen mit der Realität
Animation und Monitoring	Visuelle Darstellung und Überprüfung der Plausibilität unterschiedlicher Komponenten und Kennzahlen des Modells
Validierung im Dialog	Überprüfung der Gültigkeit des Simulationsmodells im Dialog mit Experten
Vergleich mit historischen Daten	Bewertung des Modellverhaltens mittels eines Abgleiches zwischen Kennzahlen des Modells und Kennzahlen der Realität

Gemeinsam mit Experten wurde das Simulationsmodell hinsichtlich der Gültigkeit im Zuge eines gemeinsamen Workshops diskutiert und für den vorgestellten Anwendungsfall positiv beschieden. Im Rahmen des durchgeführten Ereignisvaliditätstest wurde insbesondere die Abfolge der aus einem Produktwechsel entstehenden Rüst- und Reinigungszeiten untersucht. Die stichprobenartige Analyse hat gezeigt, dass die Abfolge der auftretenden Ereignisse mit der Realität übereinstimmt. Zur visuellen Darstellung des Simulationsablaufs sowie der resultierenden Kennzahlen wurde die Visualisierungsoberfläche (siehe Abbildung 7-10) verwendet.

Im Folgenden erfolgt die Verifizierung des Simulationsmodells anhand eines Abgleiches der Anzahl der in der Realität produzierten Aufträge mit der Anzahl der im Simulationsmodell produzierten Aufträge. Dieses Vorgehen ist der Verifizierungstechnik *Vergleich mit historischen Daten* zuzuordnen. Abbildung 7-14 zeigt diesen Abgleich in Form eines Balkendiagramms. Auf der x-Achse sind die betrachteten Wochen aufgetragen und auf der y-Achse ist die Anzahl der produzierten Aufträge abgebildet.

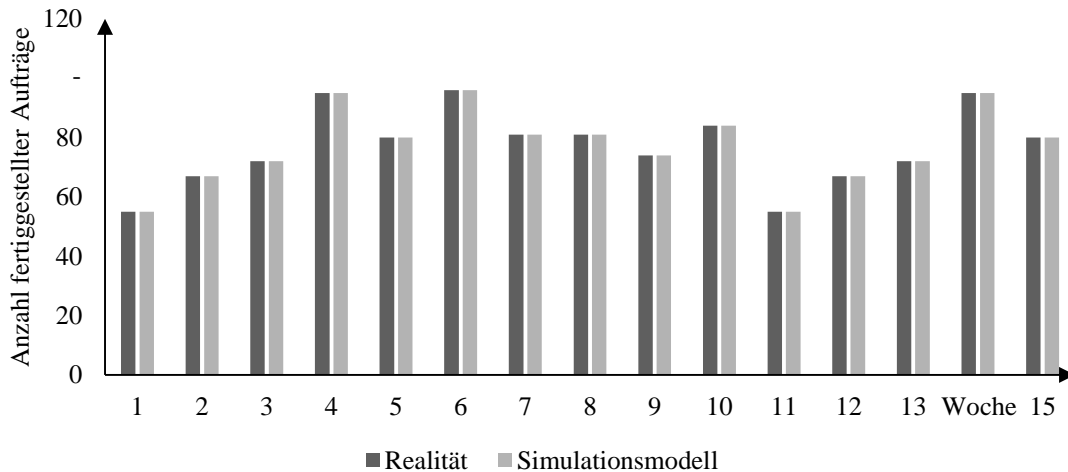


Abbildung 7-14: Verifizierung des Simulationsmodells anhand der Anzahl der pro Woche fertiggestellten Aufträge

Aufgrund der verwendeten Verifizierungstechniken kann festgehalten werden, dass das zugrunde liegende Produktionssystem durch das Simulationsmodell mit einer hinreichenden Genauigkeit abgebildet wird und zur Validierung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung eingesetzt werden kann.

7.4.3 Ergebnisse der Simulationsstudie

Alle Simulationsexperimente sowie alle dazugehörigen Berechnungen wurden auf zwei virtuellen Maschinen mit 32 x Intel® Xeon® Gold 5320 CPU @ 2.20 GHz und 192 GB RAM durchgeführt. Zur Evaluierung der Simulationsläufe wurden stets 25 Validierungsepisoden verwendet. Eine Episode entspricht dabei einer Woche.

Das für das Erlernen einer geeigneten Strategie erforderliche Training wurde anhand der Entwicklung der Belohnung überwacht. Abbildung 7-15 zeigt das Lernverhalten eines Anlagenbedieneragenten in Abhängigkeit von den durchlaufenen Iterationen. Die ca. 5 Mrd. Zeitschritte entsprechen einer Trainingszeit von ungefähr einer Woche. Nach Abschluss des Trainings konnte unter Verwendung des resultierenden Modells entweder eine Evaluierung durchgeführt oder ein weiteres Training gestartet werden.




Abbildung 7-15: Lernverhalten eines Anlagenbedieneragenten in Abhängigkeit von den Zeitschritten des Trainings

Die Bewertung der unterschiedlichen Simulationsexperimente erfolgte anhand der von ZIPFEL ET AL. (2021) entwickelten Bewertungsmetrik OPP. In Abbildung 7-16 ist die resultierende OPP der unterschiedlichen Simulationsszenarien dargestellt. Es lässt sich erkennen, dass das System zur Entscheidungsunterstützung zu einer Verbesserung der OPP führt. Allerdings ist festzuhalten, dass bei einer geringeren Reihenfolgedisziplin (Szenarien II und III) eine im Vergleich zum Referenzszenario geringere OPP erzielt wurde. Dagegen konnte mit den Szenarien, welche durch eine höhere Reihenfolgedisziplin charakterisiert sind, eine im Vergleich zum Referenzszenario bis zu 5,2 % höhere OPP erzielt werden.




Abbildung 7-16: Resultierende mittlere OPP in Abhängigkeit von den definierten Simulationsszenarien

Abbildung 7-17 zeigt die resultierende Termintreue sowie die mittlere Rüst- und Reinigungszeit für die untersuchten Simulationsszenarien. Im betrachteten Anwendungsfall stellten die Reaktion auf Störungen und das fristgerechte Fertigstellen von Eilaufträgen eine Herausforderung dar. Insbesondere die auftretenden Eilaufträge beeinflussen die Termintreue sowie die resultierenden Rüst- und Reinigungszeiten. Im Vergleich mit dem Referenzszenario konnte die Termintreue mit Hilfe des lernenden und erklärbaren Systems zur Entscheidungsunterstützung gesteigert werden. Weiterhin ist erkennbar, dass die Reihenfolgedisziplin eine starke Auswirkung auf die absoluten Rüst- und Reinigungszeiten des Produktionssystems hatte. Im Rahmen von Szenario VI sind die resultierenden Rüst- und Reinigungszeiten nur 0,8 % höher als die des Referenzszenarios. Bei den restlichen Szenarien ist die Summe der Rüst- und Reinigungszeiten teilweise erheblich höher. Dies hebt die Bedeutung der Reihenfolgedisziplin insbesondere für die resultierenden Rüst- und Reinigungszeiten hervor.




Abbildung 7-17: Durchschnittliche Rüst- und Reinigungszeit pro Episode sowie mittlere Termintreue in Abhängigkeit von den definierten Simulationsszenarien

Die Untersuchung der definierten Simulationsszenarien hat gezeigt, dass mit Hilfe des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung eine im Vergleich zum Referenzszenario (Szenario I) höhere OPP erzielt werden konnte. Somit kann geschlossen werden, dass durch den Einsatz des entwickelten Systems ein Nutzen entsteht. Dieser wird in Kapitel 8.3 dem erforderlichen Aufwand für die Realisierung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung gegenüber gestellt.

7.5 Fazit

Im Rahmen dieses Kapitels konnte anhand eines industriellen Anwendungsbeispiels gezeigt werden, dass das entwickelte lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung eingesetzt werden kann. Ausgehend von den identifizierten Benutzern konnte das Agentensystem erstellt werden. Ansätze des DRL ermöglichten durch die Interaktion mit dem Simulationsmodell einen Lernprozess der Agenten. Dies bildet die Grundlage für die zielgerichtete Auswahl von Handlungsalternativen. Zur Steigerung des Vertrauens der Mitarbeiter wurden weiterhin Erklärbarkeitsansätze integriert. Durch diese können die Mitarbeiter gezielt unterstützt und perspektivisch ihr Vertrauen in die Entscheidungen und somit die Reihenfolgedisziplin gesteigert werden.

8 Kritische Würdigung

8.1 Allgemeines

Das vorliegende Kapitel ist ebenfalls Teil der zweiten deskriptiven Studie. Die folgenden Abschnitte dienen der Validierung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung mit Hilfe einer technisch-wirtschaftlichen Bewertung. Die technische Bewertung des entwickelten Systems erfolgt hierzu auf Grundlage der definierten Anforderungen (siehe Abschnitt 3.2). In Abschnitt 8.3 erfolgt anschließend die wirtschaftliche Bewertung des Systems anhand des in Abschnitt 7.2 vorgestellten Produktionssystems des Anwendungspartners. Abschließend findet eine kritische Auseinandersetzung mit den Fähigkeiten des Systems und den gegebenen Limitationen statt (siehe Abschnitt 8.4).

8.2 Anforderungsbezogene Bewertung

Der folgende Abschnitt dient der anforderungsbezogenen Bewertung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung. Die Kriterien zur Bewertung des Systems bilden dabei die in Kapitel 4 definierten Anforderungen.

Die *Übertragbarkeit und Skalierbarkeit* des Systems gewährleistet, dass das entwickelte System auf andere Anwendungsdomänen übertragen werden kann und auch einer steigenden Komplexität, bspw. durch eine höhere Anzahl an Anlagen, gewachsen ist. Die Übertragbarkeit auf andere Anwendungsdomänen ist dann gegeben, wenn die Erstellung des Systems strukturiert und nachvollziehbar ist. In diesem Sinne ist eine gute Übertragbarkeit für das System festzustellen. Das vorgestellte Vorgehen zur Erstellung des benutzerrollenspezifischen Informationsmodells ermöglicht die unternehmensspezifische Identifikation der relevanten an der Produktionssteuerung beteiligten Benutzer sowie des zugehörigen Handlungsspielraums. Dies gestattet wiederum die unternehmensspezifische Adaption des lernenden und erklärbaren Systems zur Produktionssteuerung. Für die Modellierung wird eine generische Modellierungssprache verwendet. Die Skalierbarkeit des Systems ist einerseits durch den modularen Aufbau und andererseits durch die verwendeten DRL- und XAI-Verfahren gegeben. Diese können ebenfalls eine über

das Anwendungsbeispiel hinausgehende Komplexität bewältigen und trotzdem eine kurze Reaktionszeit gewährleisten.

Die *Berücksichtigung unterschiedlicher Benutzerrollen* bei der Systementwicklung ermöglicht die gezielte Informationsbereitstellung für unterschiedliche Benutzer in Abhängigkeit von ihren Aufgaben im Rahmen der Produktionssteuerung. In diesem Sinne ist eine Erfüllung der Anforderung erreicht. Unterschiedliche Benutzerrollen werden in der Systementwicklung berücksichtigt und bilden die Grundlage für das lernende System. Durch die Repräsentation der unterschiedlichen Benutzerrollen durch die Agenten kann eine zielgerichtete Unterstützung einzelner Benutzer mit den richtigen Informationen zur richtigen Zeit realisiert werden.

Die *Reaktionsfähigkeit auf unvorhergesehene Ereignisse* ermöglicht die adäquate Reaktion auf unvorhergesehene Ereignisse. Durch das lernende System wird innerhalb kürzester Zeit ein Entscheidungsvorschlag basierend auf dem aktuellen Zustand des Produktionssystems erzeugt. Dies trägt dazu bei, durch unvorhergesehene Ereignisse verursachte negative Auswirkungen auf das Produktionssystem zu vermeiden bzw. abzuschwächen. Das entwickelte System zur Entscheidungsunterstützung setzt für die Generierung der Entscheidungsvorschläge ein Agentensystem ein. Als Wissensbasis dient ein DNN, welches es ermöglicht, innerhalb weniger Sekunden einen Entscheidungsvorschlag zu generieren. Somit kann diese Anforderung als erfüllt erachtet werden.

Eine *multikriterielle Zielfunktion* soll die Möglichkeit bieten, unterschiedliche, teilweise gegenläufige Zielgrößen in der Zielfunktion zu berücksichtigen. Durch die Ableitung der Belohnungsfunktion aus der Zielfunktion kann diese Anforderung als erfüllt betrachtet werden. Die Belohnungsfunktion beeinflusst den Lernprozess des Agentensystems und hat dadurch einen direkten Einfluss auf die Aktionsauswahl desselben. Eine unternehmensindividuelle Priorisierung der logistischen Zielgrößen kann mit Hilfe von Gewichtungsfaktoren erreicht werden. Es hat sich gezeigt, dass die resultierenden Kosten durch das System gesenkt und insbesondere die Termintreue bei Eilaufträgen gesteigert werden kann.

Durch eine *hohe Lösungsgüte* kann einerseits die Erfüllung der logistischen Zielgrößen erreicht und andererseits das Vertrauen der Mitarbeiter in das System gestärkt werden. Wie in den vorangegangenen Abschnitten anhand der Verbesserung der OPP aufgezeigt, kann das Kriterium als erfüllt betrachtet werden. Die OPP konnten im Vergleich zum Referenzszenario um bis zu 5,2 % verbessert werden.

Somit kann die Anforderung an die hohe Lösungsgüte als erfüllt betrachtet werden.

Das Kriterium der vollständigen *Durchsuchung des Lösungsraums* stellt die Anforderung, dass die Größe des Lösungsraums nicht verfahrensbedingt durch das System eingeschränkt wird, um bspw. Vorgaben für die Rechenzeit zu erfüllen. Das im Rahmen dieser Arbeit eingesetzte Verfahren stammt aus dem Themengebiet des DRL und ermöglicht das Verarbeiten einer großen Anzahl unterschiedlicher Eingangsparameter innerhalb kürzester Zeit. Somit ist keine verfahrensbedingte Einschränkung des Lösungsraums notwendig.

Neben der hohen Lösungsgüte des Systems wird dessen Akzeptanz durch die Mitarbeiter ebenfalls von der *Erklärbarkeit des Entscheidungsprozesses* beeinflusst. Die Erklärbarkeit im Kontext von ML-Verfahren wurde im Rahmen dieser Arbeit als die Extraktion der Funktionsweise eines Modells unter Berücksichtigung des Zielpublikums definiert. In diesem Sinne kann die Anforderung als erfüllt betrachtet werden. Das entwickelte System ermöglicht das Erzeugen sowohl von globalen als auch lokalen Erklärungen. Dadurch kann den Mitarbeitern direkt aufgezeigt werden, welche Einflussfaktoren für ihre Entscheidung(en) relevant sind bzw. was sich hätte ändern müssen, damit eine andere Entscheidung getroffen worden wäre.

Zusammenfassend ist festzuhalten, dass die in Kapitel 3 definierten Anforderungen an das lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung erfüllt sind. Das System trägt zu einer verbesserten Produktionssteuerung bei und berücksichtigt dabei unterschiedliche im Produktionssystem vorkommende Benutzerrollen sowie deren Anforderungen an die Entscheidungsfindung.

8.3 Wirtschaftliche Bewertung der Anwendung

Zusätzlich zur anforderungsbezogenen Bewertung ist eine wirtschaftliche Bewertung des Systems anhand des konkreten Anwendungsbeispiels notwendig, um einen zielführenden Einsatz in weiteren produzierenden Unternehmen zu gewährleisten. Zur Bewertung erfolgt die Berechnung des Aufwands, welcher für die Erstellung des Systems notwendig ist, sowie des Nutzens, welcher durch die Anwendung des Systems entsteht. Aufwand und Nutzen werden anschließend als Grundlage für die Amortisationsdauer – eine statische Investitionsrechnung – verwendet. Ziel der Betrachtung ist es, die Amortisationszeit des lernenden und erklärbaren Systems zu berechnen.

8.3.1 Aufwand

Der Aufwand für die Realisierung des Systems kann in *einmalige* und *laufende* Betriebskosten unterteilt werden. Einmalige Betriebskosten fallen vor dem eigentlichen Betrieb an und sind zur Erstellung des Systems notwendig. Laufende Betriebskosten fallen im Betrieb kontinuierlich an und werden auf Jahresbasis ausgewiesen. Die einmaligen Betriebskosten können weiter in *Sach-* und *Personalkosten* gegliedert werden. Bei den Personalkosten handelt es sich um die Kosten, welche bei der Datenerhebung und Modellierung sowie der Adaption des Systems zur Entscheidungsunterstützung anfallen (siehe Tabelle 8-1). Das in der vorliegenden Arbeit realisierte System (siehe Abschnitt 7.2) dient als Bemessungsgrundlage für die aufgeführten Kosten.

Tabelle 8-1: Einmalige Kosten zur Erstellung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung (Expertenschätzung)

	Position	Art	Menge/ Anzahl PT	Stückkosten	Kosten
Sachkosten	S1	IT-Hardware	1	3.000 €	3.000 €
	Summe der Sachkosten				3.000 €
Personalkosten	P1	Datenerhebung und Modellierung	10	1.150 €	11.500 €
	P2	Aufbau des Simulationsmodells	30	1.150 €	34.500 €
	P3	Lernendes und erklärbares System	80	1.150 €	92.000 €
	P4	Anbindung an die bestehenden IT-Systeme	20	1.150 €	23.000 €
	P5	Schulung Personal	10	1.150 €	11.500 €
Summe der Personalkosten				172.500 €	
Gesamtsumme der einmaligen Investitionskosten				175.500 €	

Legende:

S: Sachkosten

P: Personalkosten

PT: Personentage

Die zur Realisierung des Systems zur Entscheidungsunterstützung notwendigen Sachkosten bestehen ausschließlich aus Kosten für die IT-Hardware und sind mit 3.000 € angesetzt. Bei der eingesetzten Software handelt es sich ohne Ausnahme um Open-Source-Software, weshalb dafür keine Sachkosten anfallen.

Personalkosten fallen für die zur Systemerstellung notwendigen Schritte an. Hierbei handelt es sich um das erstmalige Erfassen der Daten und die Modellierung der relevanten Benutzer sowie des Produktionssystems. Dies wiederum ermöglicht den Aufbau des Simulationsmodells für die relevanten Ausschnitte der Produktion. Für den Aufbau des Systems zur Entscheidungsunterstützung fallen einmalige Kosten in Höhe von 126.500 € an. Weiterhin ist eine Anbindung des Systems an die bestehenden IT-Systeme sowie eine Schulung der beteiligten Mitarbeiter für den Einsatz des Systems notwendig. Es ergeben sich insgesamt Personalkosten in Höhe von 172.500 €. Zusammen mit den Sachkosten führt dies zu einmaligen Investitionskosten in Höhe von 175.500 €.

Zusätzlich zu den einmaligen Investitionskosten gilt es die laufenden Kosten für den Betrieb des lernenden und erklärbaren Systems zur Entscheidungsunterstützung zu erfassen (siehe Tabelle 8-2). Diese können ebenfalls in Sach- und Personalkosten gegliedert werden. Die auftretenden Sachkosten ergeben sich aus dem Verbrauch von Rechenkapazität eines Rechenclusters und belaufen sich auf 40.000 € pro Jahr. Diese Kostenposition deckt das regelmäßige erneute Training der Agenten mit einer aktualisierten Datenbasis ab. Für den laufenden Betrieb des Systems notwendige Personalkosten setzen sich aus Servicegebühren und Kosten für die Aktualisierung des Simulationsmodells sowie des lernenden und erklärbaren Systems zusammen. Insgesamt ergeben sich laufende Betriebskosten in Höhe von 120.500 €.

Tabelle 8-2: Laufenden Kosten für den Betrieb des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung (Expertenschätzung)

	Position	Art	Menge / Anzahl PT	Stückkosten	Kosten
Sachkosten	BS 1	Kosten Rechencluster	160 h/Woche	5 €/h	40.000 €
	Summe der Sachkosten				40.000 €
Personalkosten	BP 1	Service	20	1.150 €	23.000 €
	BP 2	Aktualisierung Simulationsmodell	20	1.150 €	23.000 €
	BP 3	Aktualisierung des lernenden und erklärbaren Systems	30	1.150 €	34.500 €
	BP 4	Summe der Personalkosten			80.500 €
Gesamtsumme der laufenden Betriebskosten					120.500 €

Legende:

BS: Betriebssachkosten BP: Betriebspersonalkosten PT: Personentage

8.3.2 Nutzen

Den einmaligen und laufenden Betriebskosten steht der Nutzen gegenüber, welchen der Einsatz des Systems zur Entscheidungsunterstützung in der Produktionssteuerung mit sich bringt. Der Fokus der Betrachtung liegt auf dem quantitativen Nutzen, welcher durch die Anwendung des Systems generiert wird. Zur Bestimmung des Nutzens dient der Vergleich der Kosten, welche im Referenzszenario entstehen, mit den Kosten, welche unter Einsatz des Systems entstehen. Die Kosten wurden mittels einer Simulationsstudie ermittelt (siehe Abschnitt 7.4.1). Als Betrachtungszeitraum für die Nutzenbestimmung wurden 25 Wochen verwendet und auf 50 Wochen hochgerechnet. Tabelle 8-3 zeigt die resultierenden Kosteneinsparungen für die definierten Simulationsszenarien.

Tabelle 8-3: Nutzen der Anwendung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung anhand des Anwendungsbeispiels

	Erzielbare Kosteneinsparung pro Woche	Erzielbare Kosteneinsparung pro Jahr
Szenario II	-13.945 €	-697.237 €
Szenario III	-11.539 €	-576.933 €
Szenario IV	1.301 €	65.040 €
Szenario V	4.782 €	239.100 €
Szenario VI	7.556 €	377.794 €

Um zu beurteilen, ab welcher Zeitdauer der Kapitaleinsatz für die Implementierung des Systems sinnvoll ist, wird die Amortisationszeit verwendet. Die statische Amortisationsrechnung berechnet die Amortisationszeit entsprechend Formel (11) zu

$$Amortisationszeit [Jahre] = \frac{Kapitaleinsatz [€]}{\emptyset \text{ jährlicher Rückfluss } \left[\frac{€}{a} \right]} \quad (11)$$

mit \emptyset jährlicher Rückfluss

$$= Einsparungen \left[\frac{€}{a} \right] - Betriebskosten \left[\frac{€}{a} \right]$$

(MÜLLER 2022). Mit Hilfe dieser Formel und eines jährlichen Rückflusses für Szenario V von 118.600 € sowie für Szenario VI von 257.294 € ergibt sich eine Amortisationszeit von 1,48 bzw. 0,68 Jahren. Somit kann geschlussfolgert werden, dass das lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung grundsätzlich sowohl funktionalen als auch wirtschaftlichen Anforderungen gerecht wird.

8.4 Voraussetzungen und Limitationen

Für den Einsatz des Systems sind unterschiedliche Voraussetzungen, die erfüllt sein müssen, wie auch Limitationen zu berücksichtigen. Eine hohe *Datenverfügbarkeit* und *-qualität* gilt als grundlegende Voraussetzung dafür, dass das lernende und erklärbare System zur Entscheidungsunterstützung eingesetzt werden kann. Die Datenverfügbarkeit beschreibt das Vorhandensein der Daten, welche für das Treffen von Entscheidungen notwendig sind. Diese müssen in digitaler Form vorliegen und den aktuellen Zustand der Produktion abbilden. Besteht eine Divergenz zwischen dem tatsächlichen Zustand der Produktion und dem Zustand, welcher auf Basis der Daten zu erwarten wäre, so nimmt die Qualität der vorgeschlagenen Maßnahmen ab. Wenn Daten erfasst werden, aber die Qualität der Daten, bspw. aufgrund defekter oder vertauschter Sensoren, nicht ausreichend ist, kann dies ebenfalls einen negativen Einfluss auf die Entscheidungsqualität haben. Es lässt sich festhalten, dass durch einen Mangel an Daten oder eine schlechte Datenqualität die ohnehin bereits unter Unsicherheit getroffenen Entscheidungen der Produktionssteuerung weiter erschwert werden.

Die erforderlichen Antwortzeiten des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung können ebenfalls den Einsatz in einem Industrieunternehmen verhindern. Eine Handlungsempfehlung ohne Erklärung (Kategorie II und III) kann basierend auf dem aktuellen Zustand des Produktionssystems innerhalb von ca. 5 Sekunden getroffen werden. Ist eine zusätzliche Erklärung der einzelnen Entscheidung gewünscht (Kategorie IV und V), so ergeben sich für die Berechnung der Merkmalsrelevanz ca. 5 Sekunden und für die Ausgabe der Kontrafaktuale ca. 10 Sekunden. Ist prozesseitig eine geringere Reaktionszeit erforderlich, kann das entwickelte System nicht vollumfänglich genutzt werden.

8.5 Fazit

Im Rahmen dieses Kapitels erfolgte die Bewertung des entwickelten Systems anhand der in Kapitel 4 definierten anforderungsbezogenen Kriterien sowie hinsichtlich der Wirtschaftlichkeit in einem produktiven Betrieb. Die definierten Anforderungen an das System konnten insbesondere durch den modularen Aufbau sowie die gewählten Verfahren erfüllt werden. Mit einer Amortisationszeit von 1,48 Jahren für Szenario V und 0,68 Jahren für Szenario VI konnte der Nachweis erbracht werden, dass ein wirtschaftlicher Einsatz des entwickelten Systems möglich ist.

Der Nachweis wurde hierbei mit Hilfe einer Simulationsstudie erbracht. Limitationen in der Anwendung des Systems wurden abschließend diskutiert.

9 Zusammenfassung und Ausblick

9.1 Zusammenfassung

Das volatile Marktumfeld, der durch die Globalisierung induzierte Konkurrenzdruck sowie der Trend einer steigenden Variantenvielfalt stellen produzierende Unternehmen vor die Herausforderung, ihre Effizienz und Effektivität weiter zu steigern. Die durch diese Voraussetzungen wachsende Komplexität in den produzierenden Unternehmen erschwert eine angemessene Reaktion auf unvorhergesehene Ereignisse.

Gleichzeitig bieten sich allerdings durch den zunehmenden Einzug der Digitalisierung und den damit verbundenen Zuwachs an erfassten Rückmeldedaten aus der Produktion Chancen für die effiziente Gestaltung des Produktionsablaufs. Die Verarbeitung einer großen Menge an Daten wird begünstigt durch die steigenden Rechenkapazitäten. Dies ermöglicht den Einsatz von datenbasierten Rechenverfahren aus dem Bereich des ML zum Zweck der Produktionssteuerung.

Der Einsatz von ML-Verfahren birgt allerdings auch Herausforderungen, welche es zu adressieren gilt. Bei ML-Verfahren handelt es sich um Blackbox-Ansätze, welche das mangelnde Vertrauen der Mitarbeiter in PPS-Systeme weiter verschärfen. Eine zusätzliche Herausforderung ist das Bereitstellen der richtigen Informationen am richtigen Ort für die richtige Person, damit diese entsprechend dem aktuellen Zustand des Produktionssystems die aus Unternehmenssicht bestmögliche Entscheidung treffen kann. Vor diesem Hintergrund bestand das Ziel dieser Arbeit in der Entwicklung eines lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung.

Zur Realisierung des lernenden und erklärbaren Systems wurden die Bestandteile *benutzerrollenspezifisches Informationsmodell*, *lernende benutzerrollenspezifische Produktionssteuerung* und *Erklärbarkeit systemischer Entscheidungen* identifiziert. Das Erstellen des benutzerrollenspezifischen Informationsmodells dient der strukturierten Erfassung der an der Produktionssteuerung beteiligten Benutzer. Dies ermöglicht es, benutzerrollenindividuelle Handlungsspielräume zu identifizieren sowie den Unterstützungsbedarf initial einzuordnen. Somit können den richtigen Mitarbeitern die richtigen Informationen zur richtigen Zeit bereitgestellt

werden. Basierend auf den identifizierten Benutzerrollen werden Agenten konzeptioniert. Diese bilden die Grundlage für das System zur Entscheidungsunterstützung. Dabei ermöglicht der Einsatz von DRL die Generierung von Handlungsempfehlungen für den Mitarbeiter in Entscheidungssituationen. Hinweise dazu, welche Parameter für diese Handlungsempfehlung wichtig waren bzw. was sich verändern müsste, damit eine andere Empfehlung gegeben würde, machen die Entscheidungen des DRL-basierten Systems zur Entscheidungsunterstützung erklärbar.

Zur Erstellung des benutzerrollenspezifischen Informationsmodells wurde ein strukturiertes methodisches Vorgehen entwickelt, welches eine Leitlinie für die anwendungsfallsspezifische Anpassung bietet. Insbesondere die menschliche Entscheidungsfindung und die damit verbundenen Bias wurden eingehend analysiert. Zur Mitigation dieser Bias wurden fünf Kategorien der Entscheidungsunterstützung konzeptioniert. Die Kategorien sind Teil eines Referenzmodells, welches zusätzlich unterschiedliche Benutzerrollen sowie einen Maßnahmenreferenzkatalog mit dem Fokus der Produktionssteuerung enthält und die Grundlage für die unternehmens- und anwendungsfallsspezifische Adaption bildet.

Aus dem benutzerrollenspezifischen Informationsmodell wurde der Aufbau eines Agentensystems abgeleitet. Die einzelnen Agenten repräsentieren dabei Benutzerrollen, welche im Rahmen der Produktionssteuerung Maßnahmen initiieren können. Die Gestaltung des Beobachtungs- und Aktionsraums wird dabei an die realen Benutzerrollen angelehnt. Damit die Agenten in Abhängigkeit vom aktuellen Zustand des Produktionssystems die bestmögliche Handlungsalternative vorschlagen können, wird DRL eingesetzt. Im Rahmen dieser Arbeit wurde der Algorithmus PPO als Actor-Critic-Ansatz verwendet. Die Qualität der Aktionswahl sowie die Dauer des Trainingsverhaltens werden durch das eingesetzte Action Masking sowie den strukturierten Einsatz von Curriculum Learning positiv beeinflusst.

Damit die Entscheidungen der einzelnen Agenten nachvollziehbar sind und damit die Akzeptanz des Systems perspektivisch gesteigert wird, wurden Ansätze aus dem Bereich der XAI untersucht. Dazu wurden zwei modellagnostische Ansätze ausgewählt. Hierbei handelt es sich einerseits um ein Verfahren zur Bestimmung der Merkmalsrelevanz und andererseits um ein Verfahren zur Berechnung von Kontrafaktualen. Zur Bestimmung der Merkmalsrelevanz wurde die SHAP-Bibliothek verwendet. Mit Hilfe der SHAP-Werte kann die Bedeutung einzelner Merkmale sowohl für einzelne Entscheidungen als auch für das allgemeine Verhalten des Modells bestimmt werden.

Abschließend wurde das System anhand eines realen Anwendungsfalls simulationsbasiert erprobt und bewertet. Die Bewertung wurde anhand von anwendungsbezogenen Anforderungen sowie mit Hilfe einer technisch-wirtschaftlichen Betrachtung durchgeführt. Dabei hat sich gezeigt, dass durch den Einsatz des Systems eine Reaktion auf kurzfristige Ereignisse unter Berücksichtigung der wirtschaftlichen Auswirkungen möglich ist. Somit kann festgehalten werden, dass mit dem in der vorliegenden Arbeit entwickelten System ein Beitrag zum Einsatz von Entscheidungsunterstützungssystemen in der Produktionssteuerung geleistet wurde.

9.2 Ausblick

In der vorliegenden Arbeit konnte ein lernendes und erklärbares System zur Entscheidungsunterstützung entwickelt werden, welches Mitarbeiter in komplexen Entscheidungssituationen der Produktionssteuerung unterstützt. Basierend auf den erarbeiteten Erkenntnissen wurden weiterführende Forschungsfelder identifiziert, welche im Folgenden näher erläutert werden.

Für den Lernprozess der Agenten ist die Interaktion mit einem Produktionssystem unabdingbar. Aufgrund des anfänglich hohen Anteils an explorativen Aktionen ist hierfür ein Simulationsmodell des Produktionssystems geeignet. Durch die Interaktionen mit diesem lernt das Agentensystem das gewünschte Verhalten. Allerdings erfordert der Aufbau eines Simulationsmodells des Produktionssystems einen hohen manuellen Aufwand. Ansätze zur automatisierten Generierung eines Simulationsmodells bieten hier ein erhebliches Potenzial. Ein möglicher Lösungsansatz ist die Verwendung von Verwaltungsschalen zur Generierung eines simulationsfähigen Modells. Mit Hilfe dieses Ansatzes wäre eine Reduzierung des Arbeitsaufwands für die Erstellung möglich. Weiterhin könnte somit eine stets aktuelle Datenbasis für das Simulationsmodell gewährleistet werden.

Das eingesetzte System fokussiert im vorgestellten Stand mit der Auftragsfreigabe, der Reihenfolgebildung sowie der Kapazitätssteuerung die Aufgaben der Produktionssteuerung. Die optimale Einstellung wichtiger Betriebsparameter von Anlagen (z. B. temporär erhöhte Bearbeitungsgeschwindigkeit) in Abhängigkeit von dem zu fertigenden Produkt sowie anderen charakteristischen Merkmalen könnte ergänzt werden.

Aufbauend auf dem entwickelten System gilt es die Bedienoberfläche detailliert auszugestalten. Ziel sollte es sein, einerseits die relevanten Informationen bestmöglich zu visualisieren und andererseits die Ergonomie für die Benutzung zu

steigern. Dies könnte in produzierenden Unternehmen teilweise vorhandene Hemmschwellen für die Einführung und Benutzung von IT-Systemen weiter reduzieren.

Durch einen Austausch steuerungsrelevanter Informationen mit vor- und nachgelagerten Stufen in der Wertschöpfungskette können die Entscheidungen, welche im Rahmen der unternehmensinternen Produktionssteuerung getroffen werden, weiter verbessert werden. Diese Informationen (z. B. Lieferverzug bei einem Vorprodukt, Prognosen über den Absatz) können die Initiierung der unternehmensinternen Maßnahmen der Produktionssteuerung beeinflussen. Allerdings ist für diese Art von unternehmensübergreifendem Informationsaustausch ein geeigneter Rahmen zu schaffen. Dieser muss einen sicheren Datenaustausch ermöglichen und zusätzlich einen Anreiz für den unternehmensübergreifenden Datenaustausch schaffen.

Die aufgezeigten Forschungsbedarfe ermöglichen weitere Verbesserungen des entwickelten Systems, die zu einer größeren Akzeptanz bei den Mitarbeitern beitragen könnten.

10 Literaturverzeichnis

ADADI & BERRADA 2018

Adadi, A.; Berrada, M.: Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access* 6 (2018), S. 52138-52160.

ALTENMÜLLER ET AL. 2020

Altenmüller, T.; Stüker, T.; Waschneck, B.; Kuhnle, A.; Lanza, G.: Reinforcement learning for an intelligent and autonomous production control of complex job-shops under time constraints. *Production Engineering* 14 (2020) 3, S. 319-328.

AMIR & AMIR 2018

Amir, D.; Amir, O.: HIGHLIGHTS: Summarizing Agent Behavior to People. In: André, E. et al. (Hrsg.): *Proceedings of the 17th International Conference on Autonomous Agents and Multiagent Systems*. Stockholm, Sweden: International Foundation for Autonomous Agents and Multiagent Systems 2018, S. 1168-1176.

AMODEI & HERNANDEZ 2018

Amodei, D.; Hernandez, D.: AI and compute. <<https://openai.com/research/ai-and-compute>> - 06.03.2023.

ANDERS ET AL. 2021

Anders, S.; Biedermann, H.; Dix, Y.; Dombrowski, U.; Franz, K.; Gemeiner, A.; Gerkens, U.; Hoffmann, T.; Huke, P.; Intra, C.; Knake, H.; Krenkel, P.; Meeser, M.; Mielke, T.; Nottbohm, H.; Nyhuis, F.; Opritescu, D.; Patzelt, K.; Rennemann, T.; Richter, T.; Wullbrandt, J.; Zahn, T.: Handlungsfelder des Produktionsmanagements. In: Dombrowski, U. et al. (Hrsg.): *Ganzheitliches Produktionsmanagement*. Heidelberg: Springer Heidelberg 2021, S. 89-513. ISBN: 978-3-66262-451-7.

ANDRÉ ET AL. 2018

André, E.; Koenig, S.; Dastani, M.; Sukthankar, G. (Hrsg.): *Proceedings of the 17th International Conference on Autonomous Agents and Multiagent Systems*. Stockholm, Sweden: International Foundation for Autonomous Agents and Multiagent Systems 2018.

ANSORGE 2008

Ansorge, D.: *Auftragsabwicklung in heterogenen Produktionsstrukturen mit spezifischen Planungsfreiräumen*. Diss. Technische Universität München (2008). München.

ARNOLD ET AL. 2008

Arnold, D.; Isermann, H.; Kuhn, A.; Tempelmeier, H.; Furmans, K. (Hrsg.): *Handbuch Logistik*. Heidelberg: Springer Heidelberg 2008. ISBN: 978-3-54072-928-0. (VDI-Buch).

ARULKUMARAN ET AL. 2017

Arulkumaran, K.; Deisenroth, M.; Brundage, M.; Bharath, A.: A Brief Survey of Deep Reinforcement Learning. *IEEE Signal Processing Magazine* 34 (2017) 6, S. 26-38.

AUERBACH ET AL. 2011

Auerbach, T.; Bauhoff, F.; Beckers, M.; Behnen, D.; Brecher, C.; Brosze, T.; Buchholz, G.; Büscher, C.; Corves, B.; Eppelt, U.; Esser, M.; Ewert, D.; Fayzullin, K.; Freudenberg, R.; Fritz, P.; Fuchs, S.; Gloy, Y.-S.; Gries, T.; Haag, S.; Hauck, E.; Herfs, W.; Hering, N.; Hüsing, M.; Isermann, M.; Janssen, M.; Jeschke, S.; Kausch, B.; Kempf, T.; Klocke, F.; Kratz, S.; Kuz, S.; Loosen, P.; Lose, J.; Malik, A.; Mayer, M.; Michaeli, W.; Molitor, T.; Müller, R.; Müller, S.; Odenthal, B.; Pavim, A.; Petring, D.; Poprawe, R.; Potente, T.; Pyschny, N.; Reisingen, U.; Reißmann, A.; Riedel, M.; Schenuit, H.; Schilberg, D.; Schlick, C.; Schmitt, R.; Schuh, G.; Schulz, W.; Schürmeyer, M.; Schüttler, J.; Thombansen, U.; Veselovac, D.; Vette, M.; Wagels, C.; Willms, K.; Laass, M.; Runge, S.: *Selbstoptimierende Produktionssysteme*. In: Brecher, C. (Hrsg.): *Integrative Produktionstechnik für Hochlohnländer*. Heidelberg: Springer Heidelberg 2011, S. 747-1057. ISBN: 978-3-64220-693-1.

BANK ET AL. 2021

Bank, L.; Lubert, M.; Theumer, P.; Zipfel, A.; Kämpfer, T.; Hiller, T.; Heuer, T.; Demke, T.; Mundt, C.; Köster, N.; Janke, T.; Maibaum, J.; Schmidhuber, M.: PPS-Report 2021 - Studienergebnisse 2021.

BARREDO ARRIETA ET AL. 2020

Barredo Arrieta, A.; Díaz-Rodríguez, N.; Del Ser, J.; Benetot, A.; Tabik, S.; Barbado, A.; Garcia, S.; Gil-Lopez, S.; Molina, D.; Benjamins, R.; Chatila, R.; Herrera, F.: Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion* 58 (2020), S. 82-115.

BAUER 2022

Bauer, D.: Lernende ereignisbasierte Optimierung der Produktionssteuerung für die komplexe Werkstattfertigung. Diss. Universität Stuttgart (2022). Stuttgart.

BAUERNHANSL & TEN HOMPEL 2014

Bauernhansl, T.; ten Hompel, M. (Hrsg.): *Industrie 4.0 in Produktion, Automatisierung und Logistik*. Wiesbaden: Springer Fachmedien Wiesbaden 2014. ISBN: 978-3-65804-681-1.

BEIERLE & KERN-ISBERNER 2019

Beierle, C.; Kern-Isberner, G.: *Methoden wissensbasierter Systeme - Grundlagen, Algorithmen, Anwendungen*. 6. Aufl. Wiesbaden: Springer Vieweg 2019. ISBN: 978-3-65827-084-1. (Springer eBooks Computer Science and Engineering).

BENGIO ET AL. 2009

Bengio, Y.; Louradour, J.; Collobert, R.; Weston, J.: Curriculum learning. In: Danyluk, A. et al. (Hrsg.): *Proceedings of the 26th Annual International Conference on Machine Learning, ICML '09: The 26th Annual International Conference on Machine Learning held in conjunction with the 2007 International Conference on Inductive Logic Programming*. Montreal. New York, NY, USA: ACM 2009, S. 41-48. ISBN: 978-1-60558-516-1.

BERGAMASCHI ET AL. 1997

Bergamaschi, D.; Cigolini, R.; Perona, M.; Portioli, A.: Order review and release strategies in a job shop environment: A review and a classification. *International Journal of Production Research* 35 (1997) 2, S. 399-420.

BLESSING & CHAKRABARTI 2009

Blessing, L.; Chakrabarti, A.: *DRM, a Design Research Methodology*. London: Springer London 2009. ISBN: 978-1-84882-586-4.

BLOCK ET AL. 2016

Block, C.; Morlock, F.; Dorka, T.; Kuhlenkötter, B.: A Human Centered Multi-Agent-System for Production Planning and Control. *Applied Mechanics and Materials* 840 (2016), S. 132-139.

BODENDORF 2006

Bodendorf, F.: *Daten- und Wissensmanagement*. Heidelberg: Springer Heidelberg 2006. ISBN: 978-3-54028-743-8.

BONGAERTS ET AL. 2000

Bongaerts, L.; Monostori, L.; McFarlane, D.; Kádár, B.: Hierarchy in distributed shop floor control. *Computers in Industry* 43 (2000) 2, S. 123-137.

BOTTHOF & HARTMANN 2015

Botthof, A.; Hartmann, E. (Hrsg.): *Zukunft der Arbeit in Industrie 4.0*. Heidelberg: Springer Heidelberg 2015. ISBN: 978-3-66245-914-0.

BRAMBRING 2017

Brambring, F.: *Steigerung der Datenintegrität in der Produktionssteuerung*. Diss. Rheinisch-Westfälische Technische Hochschule Aachen (2017). Aachen.

BRECHER 2011

Brecher, C. (Hrsg.): *Integrative Produktionstechnik für Hochlohnländer*. Heidelberg: Springer Heidelberg 2011. ISBN: 978-3-64220-693-1.

BRETZKE 1980

Bretzke, W.-R.: Der Problembezug von Entscheidungsmodellen. Habil. Universität zu Köln (1980). Köln.

BREWSTER ET AL. 2019

BREWSTER ET AL.: Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems, CHI '19: CHI Conference on Human Factors in Computing Systems. Glasgow. New York: ACM 2019. ISBN: 978-1-45035-970-2.

BURKART 2022

Burkart, N.: Erklärbare Künstliche Intelligenz - Steigerung der Nachvollziehbarkeit überwachter maschineller Lernverfahren. Diss. Karlsruher Institut für Technologie (2022). Karlsruhe.

BURKART ET AL. 2021

Burkart, N.; Robert, S.; Huber, M.: Are you sure? Prediction revision in automated decision-making. Expert Systems 38 (2021) 1, e12577.

BUYYA ET AL. 2016

Buyya, R.; Calheiros, R.; Dastjerdi, A. (Hrsg.): Big Data - Principles and paradigms. Amsterdam, Boston, Heidelberg, London, New York, Oxford, Paris, San Diego, San Francisco, Singapore, Sydney, Tokyo: Morgan Kaufmann is an imprint of Elsevier 2016. ISBN: 978-0-12805-394-2.

BYRNE ET AL. 2018

Byrne, G.; Dimitrov, D.; Monostori, L.; Teti, R.; van Houten, F.; Wertheim, R.: Biologicalisation: Biological transformation in manufacturing. CIRP Journal of Manufacturing Science and Technology 21 (2018), S. 1-32.

BYRNE 2016

Byrne, R.: Counterfactual Thought. Annual review of psychology 67 (2016), S. 135-157.

CADAVID ET AL. 2020

Cadavid, J.; Lamouri, S.; Grabot, B.; Pellerin, R.; Fortin, A.: Machine learning applied in production planning and control: a state-of-the-art in the era of industry 4.0. Journal of Intelligent Manufacturing 31 (2020) 6, S. 1531-1558.

CARIDI & CAVALIERI 2004

Caridi, M.; Cavalieri, S.: Multi-agent systems in production planning and control: an overview. Production Planning & Control 15 (2004) 2, S. 106-118.

CHANG ET AL. 2003

Chang, Y.-H.; Ho, T.; Kaelbling, L.: All learning is local: Multi-agent learning in global reward games. In: Thrun, S. et al. (Hrsg.): Advances in Neural Information Processing Systems 16. Cambridge: MIT Press 2003. ISBN: 978-0-26220-152-0.

COHN 2004

Cohn, M.: User stories applied - For agile software development. 13. Aufl. Boston: Addison-Wesley 2004. ISBN: 978-0-321-20568-1. (Addison-Wesley signature series).

CONRAD & SCHREYÖGG 1996

Conrad, P.; Schreyögg, G. (Hrsg.): Wissensmanagement. Berlin: De Gruyter 1996. ISBN: 978-3-11242-184-0. (Managementforschung 6).

COOPER 2021

Cooper, A.: Explaining Machine Learning Models - A Non-Technical Guide to Interpreting SHAP Analyses. <<https://www.aidancooper.co.uk/a-non-technical-guide-to-interpreting-shap-analyses/?xgtab&>> - 27.03.2023.

CORSTEN H. & FRIEDL B. 1999

Corsten H.; Friedl B. (Hrsg.): Einführung in das Produktionscontrolling. München: Vahlen 1999. ISBN: 978-3-80062-322-8.

DANYLUK ET AL. 2009

DANYLUK ET AL.: Proceedings of the 26th Annual International Conference on Machine Learning, ICML '09: The 26th Annual International Conference on Machine Learning held in conjunction with the 2007

International Conference on Inductive Logic Programming. Montreal. New York, NY, USA: ACM 2009. ISBN: 978-1-60558-516-1.

DIN EN ISO 9241-11

DIN EN ISO 9241: Ergonomie der Mensch-System-Interaktion - Teil 11: Gebrauchstauglichkeit: Begriffe und Konzepte. Berlin: Beuth 2018.

DIN EN ISO 9241-210

DIN EN ISO 9241: Ergonomie der Mensch-System-Interaktion - Teil 210: Menschzentrierte Gestaltung interaktiver Systeme. Berlin: Beuth 2020.

DIN EN ISO/IEC 25063

DIN EN ISO/IEC 25063: System- und Software-Engineering - Qualitätskriterien und Bewertung von Systemen und Softwareprodukten (SQuaRE) -. Berlin: Beuth 2017.

DITTRICH & FOHLMEISTER 2020

Dittrich, M.-A.; Fohlmeister, S.: Cooperative multi-agent system for production control using reinforcement learning. CIRP Annals 69 (2020) 1, S. 389-392.

DÖBEL ET AL. 2018

Döbel, I.; Leis, M.; Molina Vogelsang, M.; Welz, J.; d. Neustroev; Petzka, H.; Riemer, A.; Püping, S.; Voss, A.; Wegele, M.: Maschinelles Lernen - Eine Analyse zu Kompetenzen, Forschung und Anwendung. München: Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. 2018.

DOMBROWSKI & KRENKEL 2021

Dombrowski, U.; Krenkel, P. (Hrsg.): Ganzheitliches Produktionsmanagement. Heidelberg: Springer Heidelberg 2021. ISBN: 978-3-66262-451-7.

DONG ET AL. 2020

Dong, H.; Ding, Z.; Zhang, S. (Hrsg.): Deep Reinforcement Learning. Singapore: Springer Singapore 2020. ISBN: 978-9-81154-094-3.

DU & DING 2021

Du, W.; Ding, S.: A survey on multi-agent deep reinforcement learning: from the perspective of challenges and applications. Artificial Intelligence Review 54 (2021) 5, S. 3215-3238.

DUDENREDAKTION 2023

Dudenredaktion: Bias. <<https://www.duden.de/rechtschreibung/Bias>> - 05.10.2023.

DUDENREDAKTION 2024

Dudenredaktion: Erklärbarkeit. <<https://www.duden.de/rechtschreibung/Erklaerbarkeit>> - 24.03.2024.

DY & KRAUSE 2018

Dy, J.; Krause, A. (Hrsg.): Proceedings of the 35th International Conference on Machine Learning. Proceedings of Machine Learning Research: PMLR 2018.

ECKERT ET AL. 2012

Eckert, K.; Fay, A.; Hadlich, T.; Diedrich, C.; Frank, T.; Vogel-Heuser, B.: Design patterns for distributed automation systems with consideration of non-functional requirements. In: IEEE (Hrsg.): 2012 IEEE 17th International Conference on Emerging Technologies & Factory Automation (ETFA 2012). Krakow: IEEE 2012, S. 1-9. ISBN: 978-1-46734-737-2.

ELMARAGHY ET AL. 2012

ElMaraghy, W.; ElMaraghy, H.; Tomiyama, T.; Monostori, L.: Complexity in engineering design and manufacturing. CIRP Annals 61 (2012) 2, S. 793-814.

ENGELHARDT 2015

Engelhardt, P.: System für die RFID-gestützte situationsbasierte Produktionssteuerung in der auftragsbezogenen Fertigung und Montage. Technische Universität München (2015). München.

ERBER 2023

Erber, F.: Reaktion auf unvorhergesehene Ereignisse mittels Reinforcement Learning im Kontext der Produktionssteuerung. Masterarbeit. Lehrstuhl für Produktionsinformatik, Universität Augsburg (2023). Augsburg.

ERLACH 2020

Erlach, K.: Wertstromdesign - Der Weg zur schlanken Fabrik. Springer Vieweg. 3. Aufl. Berlin, Heidelberg: Springer Vieweg 2020. ISBN: 978-3-66258-906-9. (VDI-Buch).

EVERSHEIM 2002

Eversheim, W.: Organisation in der Produktionstechnik 3 - Arbeitsvorbereitung. 4. Aufl. Heidelberg: Springer Heidelberg 2002. ISBN: 978-3-64256-336-2.

FELDMANN & REINHART 2000

Feldmann, K.; Reinhart, G. (Hrsg.): Simulationsbasierte Planungssysteme für Organisation und Produktion - Modellaufbau, Simulationsexperimente, Einsatzbeispiele. Heidelberg: Springer Heidelberg 2000. ISBN: 978-3-66242-588-6.

FETTKE & LOOS 2004a

Fettke, P.; Loos, P.: Referenzmodellierungsforschung – Langfassung eines Aufsatzes. In: Loos, P. (Hrsg.): Working Papers of the Research Group Information Systems & Management. Mainz 2004.

FETTKE & LOOS 2004b

Fettke, P.; Loos, P.: Entwicklung eines Bezugsrahmens zur Evaluierung von Referenzmodellen - Langfassung eines Beitrags. In: Loos, P. (Hrsg.): Working Papers of the Research Group Information Systems & Management. Mainz 2004.

FILIPE ET AL. 2021

FILIPE ET AL.: Proceedings of the 23rd International Conference on Enterprise Information Systems, 23rd International Conference on Enterprise Information Systems: SCITEPRESS - Science and Technology Publications 2021. ISBN: 978-3-03108-965-7.

FRANÇOIS-LAVET ET AL. 2018

François-Lavet, V.; Henderson, P.; Islam, R.; Bellemare, M.; Pineau, J.: An Introduction to Deep Reinforcement Learning. Foundations and Trends® in Machine Learning 11 (2018) 3-4, S. 219-354.

GILPIN ET AL. 2018

Gilpin, L.; Bau, D.; Yuan, B.; Bajwa, A.; Specter, M.; Kagal, L.: Explaining Explanations: An Overview of Interpretability of Machine Learning 2018.

GOODFELLOW ET AL. 2016

Goodfellow, I.; Bengio, Y.; Courville, A.: Deep Learning: MIT Press 2016. ISBN: 978-0-26233-737-3.

GRONAUER & DIEPOLD 2022

Gronauer, S.; Diepold, K.: Multi-agent deep reinforcement learning: a survey. Artificial Intelligence Review 55 (2022) 2, S. 895-943.

GROTE 2005

Grote, G.: Menschliche Kontrolle über technische Systeme. In: Karrer, K. et al. (Hrsg.): Beiträge zur Mensch-Maschine-Systemtechnik aus Forschung und Praxis : Festschrift für Klaus-Peter Timpe. Düsseldorf: Symposium 2005, S. 65-78. ISBN: 978-3-93660-872-4.

GUIDOTTI ET AL. 2019

Guidotti, R.; Monreale, A.; Giannotti, F.; Pedreschi, D.; Ruggieri, S.; Turini, F.: Factual and Counterfactual Explanations for Black Box Decision Making. IEEE Intelligent Systems 34 (2019) 6, S. 14-23.

GUTENBERG 1971

Gutenberg, E.: Grundlagen der Betriebswirtschaftslehre - Die Produktion. 24. Aufl. Berlin, Heidelberg: Springer Berlin Heidelberg 1971. ISBN: 978-3-64261-990-8. (Enzyklopädie der Rechts- und Staatswissenschaft).

HACKSTEIN 1989

Hackstein, R.: Produktionsplanung und -steuerung (PPS) - Ein Handbuch für die Betriebspraxis. 2. Aufl. Düsseldorf: VDI-Verl. 1989. ISBN: 978-3-18400-924-3.

HEINEN ET AL. 2008

Heinen, T.; Rimpau, C.; Wörn, A.: Wandlungsfähigkeit als Ziel der Produktionssystemgestaltung. In: Nyhuis, P. et al. (Hrsg.): Wandlungsfähige Produktionssysteme. Heute die Industrie von morgen gestalten. Garbsen: PZH Produktionstechnisches Zentrum 2008, 19-32. ISBN: 978-3-93902-696-9.

HENELIUS ET AL. 2014

Henelius, A.; Puolamäki, K.; Boström, H.; Asker, L.; Papapetrou, P.: A peek into the black box: exploring classifiers by randomization. *Data Mining and Knowledge Discovery* 28 (2014) 5-6, S. 1503-1529.

HERBERGER & HÜBNER 2022

HERBERGER & HÜBNER: Proceedings of the Conference on Production Systems and Logistics: CPSL 2022. Hannover: publish-Ing. 2022.

HILDEBRANDT ET AL. 2020

HILDEBRANDT ET AL.: Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency. New York, USA: Association for Computing Machinery 2020. ISBN: 978-1-45036-936-7.

HILTON 1990

Hilton, D.: Conversational processes and causal explanation. *Psychological Bulletin* 107 (1990) 1, S. 65-81.

HINRICHSSEN & BORNEWASSER 2019

Hinrichsen, S.; Bornewasser, M.: How to Design Assembly Assistance Systems. In: Karwowski, W. et al. (Hrsg.): Proceedings of the 2nd International Conference on Intelligent Human Systems Integration (IHSI 2019): Integrating People and Intelligent Systems. Cham: Springer Cham 2019, S. 286-292. ISBN: 978-3-03011-050-5. (Advances in Intelligent Systems and Computing 903).

HIRSCH-KREINSEN 2015

Hirsch-Kreinsen, H.: Entwicklungsperspektiven von Produktionsarbeit. In: Botthof, A. et al. (Hrsg.): Zukunft der Arbeit in Industrie 4.0. Heidelberg: Springer Heidelberg 2015, S. 89-98. ISBN: 978-3-66245-914-0.

HÖRMANN 2022

Hörmann, B.: Entscheidungsunterstützung in der Produktionssteuerung mittels erklärbarem Reinforcement Learning. Masterarbeit. Institut für Werkzeugmaschinen und Betriebswissenschaften (*iwb*), Technische Universität München (2022). München.

HUANG & ONTAÑÓN 2022

Huang, S.; Ontañón, S.: A Closer Look at Invalid Action Masking in Policy Gradient Algorithms. *The International FLAIRS Conference Proceedings* 35 (2022).

HUBER ET AL. 2021

Huber, T.; Weitz, K.; André, E.; Amir, O.: Local and global explanations of agent behavior: Integrating strategy summaries with saliency maps. *Artificial Intelligence* 301 (2021), S. 103571.

I. GUYON ET AL. 2017

I. GUYON ET AL.: Proceedings of Advances in Neural Information Processing Systems 30: Curran Associates, Inc 2017. ISBN: 978-1-51086-096-4.

IEEE 2012

IEEE: 2012 IEEE 17th International Conference on Emerging Technologies & Factory Automation (ETFAs 2012). Krakow: IEEE 2012. ISBN: 978-1-46734-737-2.

IEEE 2016

IEEE: 2016 IEEE International Conference on Industrial Technology (ICIT), 2016 IEEE International Conference on Industrial Technology (ICIT). Taipei, Taiwan: IEEE 2016. ISBN: 978-1-46738-075-1.

IEEE 2020

IEEE: 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Toronto: IEEE 2020. ISBN: 978-1-72818-526-2.

JENNINGS 2001

Jennings, N.: An agent-based approach for building complex software systems. *Communications of the ACM* 44 (2001) 4, S. 35-41.

JOSHI 2020

Joshi, A.: Machine Learning and Artificial Intelligence. Cham: Springer Cham 2020. ISBN: 978-3-03026-621-9.

KAHNEMAN 2012

Kahneman, D.: Thinking, fast and slow. London: Penguin Books 2012. ISBN: 978-0-14103-357-0. (Penguin psychology).

KARRER ET AL. 2005

Karrer, K.; Gauss, B.; Christiane, S. (Hrsg.): Beiträge zur Mensch-Maschine-Systemtechnik aus Forschung und Praxis : Festschrift für Klaus-Peter Timpe. Düsseldorf: Symposium 2005. ISBN: 978-3-93660-872-4.

KARWOWSKI & AHRAM 2019

KARWOWSKI & AHRAM: Proceedings of the 2nd International Conference on Intelligent Human Systems Integration (IHSI 2019): Integrating People and Intelligent Systems. Cham: Springer Cham 2019. ISBN: 978-3-03011-050-5. (Advances in Intelligent Systems and Computing 903).

KASIE ET AL. 2017

Kasie, F.; Bright, G.; Walker, A.: Decision support systems in manufacturing: a survey and future trends. Journal of Modelling in Management 12 (2017) 3, S. 432-454.

KAUFMANN 2021

Kaufmann, T.: Strategiewerkzeuge aus der Praxis - Analyse und Beurteilung der strategischen Ausgangslage. Heidelberg: Springer Heidelberg 2021. ISBN: 978-3-66263-104-1.

KERSTEN ET AL. 2014

KERSTEN ET AL.: Industrie 4.0 - Wie intelligente Vernetzung und kognitive Systeme unsere Arbeit verändern. Berlin: GITO 2014. ISBN: 978-3-95545-083-0. (Schriftenreihe der Hochschulgruppe für Arbeits- und Betriebsorganisation e.V. (HAB)).

KIEFER 2020

Kiefer, L.: Gestaltung und Planung von merkmals- und agentenbasierten Selbststeuerungssystemen für die autonome Produktion. Diss. Technische Universität München (2020). München.

KLETTI 2015a

Kletti, J. (Hrsg.): MES - Manufacturing Execution System - Moderne Informationstechnologie unterstützt die Wertschöpfung. 2. Aufl. Heidelberg: Springer Vieweg 2015. ISBN: 978-3-66246-902-6.

KLETTI 2015b

Kletti, J.: Die Anforderungen an die moderne Produktion. In: Kletti, J. (Hrsg.): MES - Manufacturing Execution System. Moderne Informationstechnologie unterstützt die Wertschöpfung. 2. Auflage Aufl. Heidelberg: Springer Vieweg 2015, S. 1-18. ISBN: 978-3-66246-902-6.

KLETTI 2015c

Kletti, J.: MES – Informationsmanagement in der Fertigung. In: Kletti, J. (Hrsg.): MES - Manufacturing Execution System. Moderne Informationstechnologie unterstützt die Wertschöpfung. 2. Auflage Aufl. Heidelberg: Springer Vieweg 2015. ISBN: 978-3-66246-902-6.

KLETTI & DEISENROTH 2021

Kletti, J.; Deisenroth, R.: Lehrbuch für digitales Fertigungsmanagement - Manufacturing Execution Systems - MES. Berlin, Heidelberg: Springer Vieweg 2021. ISBN: 978-3-66263-201-7. (Lehrbuch).

KLÖBER-KOCH 2021

Klöber-Koch, J.: System zur operativen Produktionsplanung unter Berücksichtigung der Risikopräferenz. Diss. Technische Universität München (2021). München.

KÖHLER 1977

Köhler, R. (Hrsg.): Empirische und handlungstheoretische Forschungskonzeptionen in der Betriebswirtschaftslehre. Stuttgart: Schäffer-Poeschel Verlag 1977. ISBN: 978-3-79100-214-9.

KRCMAR 2015

Krcmar, H.: Informationsmanagement. 6. Aufl. Heidelberg: Springer Gabler 2015. ISBN: 978-3-66245-862-4.

KRUSE 2023

Kruse, S.: User-Centric Explainable Deep Reinforcement Learning for Decision Support Systems. Bachelorarbeit. Big Data Analytics Gruppe, Philipps-Universität Marburg (2023). Marburg.

KUBICEK 1977

Kubicek, H.: Heuristische Bezugsrahmen und heuristisch angelegte Forschungsdesigns als Elemente einer Konstruktionsstrategie empirischer Forschung. In: Köhler, R. (Hrsg.): Empirische und handlungstheoretische Forschungskonzeptionen in der Betriebswirtschaftslehre. Stuttgart: Schäffer-Poeschel Verlag 1977. ISBN: 978-3-79100-214-9.

KUHN & TUCKER 1953

Kuhn, H.; Tucker, A. (Hrsg.): Contributions to the Theory of Games II. Princeton: Princeton University Press 1953.

KUHNLE 2020

Kuhnle, A.: Adaptive Order Dispatching based on Reinforcement Learning: Application in a Complex Job Shop in the Semiconductor Industry. Diss. Karlsruher Institut für Technologie (2020). Karlsruhe.

KUHNLE ET AL. 2021

Kuhnle, A.; May, M.; Schäfer, L.; Lanza, G.: Explainable reinforcement learning in production control of job shop manufacturing system. International Journal of Production Research 24 (2021) 4, S. 1-23.

KUYUMCU 2013

Kuyumcu, A.: Modellierung der Termintreue in der Produktion. Diss. Technische Universität Hamburg-Harburg (2013). Hamburg.

LANGER ET AL. 2021

Langer, M.; Oster, D.; Speith, T.; Hermanns, H.; Kästner, L.; Schmidt, E.; Sesing, A.; Baum, K.: What do we want from Explainable Artificial Intelligence (XAI)? – A stakeholder perspective on XAI and a conceptual model guiding interdisciplinary XAI research. Artificial Intelligence 296 (2021), S. 103473.

LASI ET AL. 2014

Lasi, H.; Fettke, P.; Kemper, H.-G.; Feld, T.; Hoffmann, M.: Industry 4.0. Business & Information Systems Engineering 6 (2014) 4, S. 239-242.

LAUX ET AL. 2018

Laux, H.; Gillenkirch, R.; Schenk-Mathes, H.: Entscheidungstheorie. 10. Aufl. Berlin: Springer Gabler 2018. ISBN: 978-3-642-55258-8. (Springer-Lehrbuch).

LAUX & LIERMANN 2005

Laux, H.; Liermann, F.: Grundlagen der Organisation - Die Steuerung von Entscheidungen als Grundproblem der Betriebswirtschaftslehre. 6. Aufl. Berlin: Springer 2005. ISBN: 978-3-540-24436-3. (Springer-Lehrbuch).

LEE & SEE 2004

Lee, J.; See, K.: Trust in automation: designing for appropriate reliance. Human Factors 46 (2004) 1, S. 50-80.

LEITÃO & KARNOUSKOS 2015

Leitão, P.; Karnouskos, S. (Hrsg.): Industrial Agents - Emerging Applications of Software Agents in Industry. Boston: Elsevier 2015. ISBN: 978-0-12800-341-1.

LEUSIN ET AL. 2018

Leusin, M.; Kück, M.; Frazzon, E.; Maldonado, M.; Freitag, M.: Potential of a Multi-Agent System Approach for Production Control in Smart Factories. IFAC-PapersOnLine 51 (2018) 11, S. 1459-1464.

LIANG ET AL. 2018

Liang, E.; Liaw, R.; Nishihara, R.; Moritz, P.; Fox, R.; Goldberg, K.; Gonzalez, J.; Jordan, M.; Stoica, I.: RLlib: Abstractions for Distributed Reinforcement Learning. In: Dy, J. et al. (Hrsg.): Proceedings of the 35th International Conference on Machine Learning. Proceedings of Machine Learning Research: PMLR 2018, 3053-3062.

LÖDDING 2019

Lödding, H. (Hrsg.): PPS-Report 2019 - Studienergebnisse. 1. Aufl. Garbsen: TEWISS 2019. ISBN: 978-3-95900-402-2.

LÖDDING 2016

Lödning, H.: Verfahren der Fertigungssteuerung - Grundlagen, Beschreibung, Konfiguration. 3. Aufl. 2016. ISBN: 978-3-662-48458-6. (VDI-Buch).

LOOS 2004

Loos, P. (Hrsg.): Working Papers of the Research Group Information Systems & Management. Johannes Gutenberg-University Mainz - ISYM - Information Systems & Management. Mainz 2004.

LOOS 1999

Loos, P.: Grunddatenverwaltung und Betriebsdatenerfassung als Basis der Produktionsplanung und -steuerung. In: Corsten H. et al. (Hrsg.): Einführung in das Produktionscontrolling. München: Vahlen 1999, S. 227-252. ISBN: 978-3-80062-322-8.

LUNDBERG & LEE 2017

Lundberg, S.; Lee, S.-I.: A Unified Approach to Interpreting Model Predictions. In: I. Guyon et al. (Hrsg.): Proceedings of Advances in Neural Information Processing Systems 30: Curran Associates, Inc 2017. ISBN: 978-1-51086-096-4.

MAAG 2023

Maag, F.: Reward Design für Multiagent-Deep-Reinforcement-Learning im Kontext der Produktionssteuerung. Masterarbeit. Hochschule Ansbach (2023). Ansbach.

MADUMAL ET AL. 2020

Madumal, P.; Miller, T.; Sonenberg, L.; Vetere, F.: Explainable Reinforcement Learning through a Causal Lens. Proceedings of the AAAI Conference on Artificial Intelligence 34 (2020) 03, S. 2493-2500.

MAY ET AL. 2021

May, M.; Kiefer, L.; Kuhnle, A.; Stricker, N.; Lanza, G.: Decentralized Multi-Agent Production Control through Economic Model Bidding for Matrix Production Systems. Procedia CIRP 96 (2021), S. 3-8.

MEIßNER ET AL. 2015

Meißner, J.; Maasem, C.; Kropp, S.: Voruntersuchung „Produktion am Standort Deutschland“. In: Schuh, G. (Hrsg.): ProSense. Hochauflösende Produktionssteuerung auf Basis kybernetischer Unterstützungssysteme und intelligenter Sensorik. 1. Aufl. Aachen: Apprimus 2015. ISBN: 978-3-86359-346-9.

MINSKY 1961

Minsky, M.: Steps toward Artificial Intelligence. Proceedings of the IRE 49 (1961) 1, S. 8-30.

MOLNAR 2022

Molnar, C.: Interpretable Machine Learning. 2. Aufl. 2022. ISBN: 979-8-411-46333-0.

MONOSTORI ET AL. 2016

Monostori, L.; Kádár, B.; Bauernhansl, T.; Kondoh, S.; Kumara, S.; Reinhart, G.; Sauer, O.; Schuh, G.; Sihm, W.; Ueda, K.: Cyber-physical systems in manufacturing. CIRP Annals 65 (2016) 2, S. 621-641.

MONOSTORI ET AL. 2006

Monostori, L.; Váncza, J.; Kumara, S.: Agent-Based Systems for Manufacturing. CIRP Annals 55 (2006) 2, S. 697-720.

MONTAVON ET AL. 2018

Montavon, G.; Samek, W.; Müller, K.-R.: Methods for interpreting and understanding deep neural networks. Digital Signal Processing 73 (2018), S. 1-15.

MOTHILAL ET AL. 2020

Mothilal, R.; Sharma, A.; Tan, C.: Explaining Machine Learning Classifiers through Diverse Counterfactual Explanations. In: Hildebrandt, M. et al. (Hrsg.): Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency. New York, USA: Association for Computing Machinery 2020, S. 607-617. ISBN: 978-1-45036-936-7.

MÜLLER 2022

Müller, D.: Investitionscontrolling: Entscheidungsfindung bei Investitionen I - Investitionscontrolling und Investitionstheorie. Wiesbaden: Springer Fachmedien Wiesbaden 2022. ISBN: 978-3-65836-592-9.

MÜLLER & RIEDEL 2014

Müller, E.; Riedel, R.: Humanzentrierte Entscheidungsunterstützung in intelligent vernetzten Produktionssystemen. In: Kersten, W. et al. (Hrsg.): Industrie 4.0 - Wie intelligente Vernetzung und kognitive Systeme unsere Arbeit verändern. Berlin: GITO 2014. ISBN: 978-3-95545-083-0. (Schriftenreihe der Hochschulgruppe für Arbeits- und Betriebsorganisation e.V. (HAB)).

MÜLLER & LENZ 2013

Müller, R.; Lenz, H.-J.: Business Intelligence. Heidelberg: Springer Vieweg 2013. ISBN: 978-3-64235-559-2.

MURDOCH ET AL. 2019

Murdoch, W.; Singh, C.; Kumbier, K.; Abbasi-Asl, R.; Yu, B.: Definitions, methods, and applications in interpretable machine learning. Proceedings of the National Academy of Sciences of the United States of America 116 (2019) 44, S. 22071-22080.

NARVEKAR ET AL. 2020

Narvekar, S.; Peng, B.; Leonetti, M.; Sinapov, J.; Taylor, M.; Stone, P.: Curriculum learning for reinforcement learning domains: A framework and survey. Journal of machine learning research 21 (2020), S. 1-50.

NELLES ET AL. 2016

Nelles, J.; Kuz, S.; Mertens, A.; Schlick, C.: Human-centered design of assistance systems for production planning and control: The role of the human in Industry 4.0. In: IEEE (Hrsg.): 2016 IEEE International Conference on Industrial Technology (ICIT), 2016 IEEE International Conference on Industrial Technology (ICIT). Taipei, Taiwan: IEEE 2016, S. 2099-2104. ISBN: 978-1-46738-075-1.

NIEHUES 2016

Niehues, M.: Adaptive Produktionssteuerung für Werkstattfertigungssysteme durch fertigungsbegleitende Reihenfolgebildung. Diss. Technische Universität München (2016). München.

NIEHUES ET AL. 2017

Niehues, M.; Reinhart, G.; Schmitt, R.; Schuh, G.; Brambring, F.; Ellerich, M.; Elser, H.; Frank, D.; Grogert, S.; Gützlaff, A.; Heinrichs, V.; Hempel, T.; Kostyszyn, K.; Ngo, H.; Niendorf, L.; Permin, E.; Prote, J.-P.; Reuter, C.; Türtmann, R.: Organisation, Qualität und IT-Systeme für Planung und Betrieb. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Carl Hanser 2017, S. 137-167. ISBN: 978-3-44644-642-7.

NUNES & JANNACH 2017

Nunes, I.; Jannach, D.: A systematic review and taxonomy of explanations in decision support and recommender systems. User Modeling and User-Adapted Interaction 27 (2017) 3-5, S. 393-444.

NYHUIS 2008

Nyhuis, P. (Hrsg.): Beiträge zu einer Theorie der Logistik. Berlin, Heidelberg: Springer Berlin Heidelberg 2008. ISBN: 978-3-54075-642-2.

NYHUIS ET AL. 2008

Nyhuis, P.; Reinhart, G.; Abele, E. (Hrsg.): Wandlungsfähige Produktionssysteme - Heute die Industrie von morgen gestalten. Garbsen: PZH Produktionstechnisches Zentrum 2008. ISBN: 978-3-93902-696-9.

NYHUIS ET AL. 2016

Nyhuis, P.; Mayer, J.; Pielmeier, J.; Berger, C.; Engehausen, F.; Hempel, T.; Hünnekes, P. (Hrsg.): Aktuellen Herausforderungen der Produktionsplanung und -steuerung mittels Industrie 4.0 begegnen - Studienergebnisse. TEWISS - Technik und Wissen. Garbsen: PZH 2016. ISBN: 978-3-95900-104-5.

NYHUIS ET AL. 2020

NYHUIS ET AL.: Proceedings of the 1st Conference on Production Systems and Logistics (CPSL 2020). Hannover: publish-Ing. 2020.

NYHUIS & GERST 2008

Nyhuis, P.; Gerst, D.: Grundlagen der Produktionslogistik. In: Arnold, D. et al. (Hrsg.): Handbuch Logistik. Heidelberg: Springer Heidelberg 2008, S. 323-343. ISBN: 978-3-54072-928-0. (VDI-Buch).

NYHUIS & SCHMIDT 2008

Nyhuis, P.; Schmidt, M.: Grundlagen der Produktionslogistik. In: Arnold, D. et al. (Hrsg.): Handbuch Logistik. Heidelberg: Springer Heidelberg 2008, S. 323-343. ISBN: 978-3-54072-928-0. (VDI-Buch).

NYHUIS ET AL. 2017

Nyhuis, P.; Schmidt, M.; Hübner, M.: Transparenz durch Datenverfügbarkeit als Enabler für eine leistungsfähigere PPS. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Carl Hanser 2017. ISBN: 978-3-44644-642-7.

NYHUIS & WIENDAHL 2012

Nyhuis, P.; Wiendahl, H.-P.: Logistische Kennlinien - Grundlagen, Werkzeuge und Anwendungen. 3. Aufl. Heidelberg: Springer Heidelberg 2012. ISBN: 978-3-54092-839-3.

OLUYISOLA ET AL. 2020

Oluoyisola, O.; Sgarbossa, F.; Strandhagen, J.: Smart Production Planning and Control: Concept, Use-Cases and Sustainability Implications. Sustainability 12 (2020) 9, S. 3791.

OPENAI 2018

OpenAI: Proximal Policy Optimization. <<https://spinningup.openai.com/en/latest/algorithms/ppo.html>> - 01.03.2023.

OSTGATHE 2012

Ostgathe, M.: System zur produktbasierten Steuerung von Abläufen in der auftragsbezogenen Fertigung und Montage. Diss. TU München (2012). München.

PANZER & BENDER 2021

Panzer, M.; Bender, B.: Deep reinforcement learning in production systems: a systematic literature review. International Journal of Production Research 60 (2021) 13, S. 4316-4341.

PAPADOPOULOS ET AL. 2017

PAPADOPOULOS ET AL.: IUI'17, IUI'17: 22nd International Conference on Intelligent User Interfaces. Limassol Cyprus. New York, New York: The Association for Computing Machinery 2017. ISBN: 978-1-45034-348-0.

PARK ET AL. 2019

Park, Y.; Cho, Y.; Kim, S.: Multi-agent reinforcement learning with approximate model learning for competitive games. PLOS ONE 14 (2019).

PFISTER ET AL. 2017

Pfister, H.-R.; Jungermann, H.; Fischer, K.: Die Psychologie der Entscheidung. Heidelberg: Springer Heidelberg 2017. ISBN: 978-3-66253-037-5.

PIELMEIER 2019

Pielmeier, J.: System zur ereignisorientierten Produktionssteuerung. Diss. TU München (2019). München.

PIELMEIER ET AL. 2018

Pielmeier, J.; Theumer, P.; Braunreuther, S.; Reinhart, G.: Development of a methodology for event-based production control. Procedia CIRP 72 (2018), S. 1345-1350.

PIELMEIER ET AL. 2019

Pielmeier, J.; Theumer, P.; Schutte, C.; Snyman, S.; Bessdo, O.; Braunreuther, S.; Reinhart, G.: Method for event-based production control. Procedia CIRP 79 (2019), S. 373-378.

POL ET AL. 2021

Pol, S.; Baer, S.; Turner, D.; Samsonov, V.; Meisen, T.: Global Reward Design for Cooperative Agents to Achieve Flexible Production Control under Real-time Constraints. In: Filipe, J. et al. (Hrsg.): Proceedings of the 23rd International Conference on Enterprise Information Systems, 23rd International Conference on Enterprise Information Systems: SCITEPRESS - Science and Technology Publications 2021, S. 515-526. ISBN: 978-3-03108-965-7.

POWER 2002

Power, D.: Decision support systems - Concepts and Resources for Managers. Westport, CT: Quorum Books 2002. ISBN: 978-1-56720-497-1.

POWER 2004

Power, D.: Specifying An Expanded Framework for Classifying and Describing Decision Support Systems. *Communications of the Association for Information Systems* 13 (2004) 1, 158-166.

PRECUP & TEH 2017

PRECUP & TEH: Proceedings of the 34th International Conference on Machine Learning - Volume 70. Sydney: JMLR.org 2017.

RABE ET AL. 2008

Rabe, M.; Spieckermann, S.; Wenzel, S.: Verifikation und Validierung für die Simulation in Produktion und Logistik. Heidelberg: Springer Heidelberg 2008. ISBN: 978-3-54035-281-5.

RASHEDI 2022

Rashedi, J.: Das datengetriebene Unternehmen - Erfolgreiche Implementierung einer data-driven Organization. Springer Fachmedien Wiesbaden. Heidelberg: Springer Gabler 2022. ISBN: 978-3-65836-423-6.

REFA 1984

REFA: Methodenlehre des Arbeitsstudiums - Teil 1: Grundlagen. Verband für Arbeitsstudien - REFA. 7. Aufl. München: Carl Hanser 1984. ISBN: 978-3-44614-234-3.

REHÄUSER & KRCMAR 1996

Rehäuser, J.; Krcmar, H.: Wissensmanagement im Unternehmen. In: Conrad, P. et al. (Hrsg.): Wissensmanagement. Berlin: De Gruyter 1996, S. 1-40. ISBN: 978-3-11242-184-0. (Managementforschung 6).

REHBERGER 2020

Rehberger, S.: Combining Product- and Resource-Related Reasoning for Agent-Based Production Automation. Diss. Technische Universität München (2020). München.

REHSE ET AL. 2019

Rehse, J.-R.; Mehdiyev, N.; Fettke, P.: Towards Explainable Process Predictions for Industry 4.0 in the DFKI-Smart-Lego-Factory. *KI - Künstliche Intelligenz* 33 (2019) 2, S. 181-187.

REINHART 2017

Reinhart, G. (Hrsg.): Handbuch Industrie 4.0 - Geschäftsmodelle, Prozesse, Technik. München: Carl Hanser 2017. ISBN: 978-3-44644-642-7.

REINHART 2000

Reinhart, G.: Simulation - ein Experiment am digitalen Modell. In: Feldmann, K. et al. (Hrsg.): Simulationsbasierte Planungssysteme für Organisation und Produktion. Modellaufbau, Simulationsexperimente, Einsatzbeispiele. Heidelberg: Springer Heidelberg 2000. ISBN: 978-3-66242-588-6.

REINHART & ZÜHLKE 2017

Reinhart, G.; Zühlke, D.: Von CIM zu Industrie 4.0. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0. Geschäftsmodelle, Prozesse, Technik. München: Carl Hanser 2017, S. XXXI-XXXIV. ISBN: 978-3-44644-642-7.

REUTER & BRAMBRING 2016

Reuter, C.; Brambring, F.: Improving Data Consistency in Production Control. *Procedia CIRP* 41 (2016), S. 51-56.

RICHTER 2018

Richter, C.: Modellbasierte Entwicklung von Mensch-Maschine-Schnittstellen im Maschinen- und Anlagenbau. Diss. Technische Universität München (2018). München.

RÖSCH 2021

Rösch, M.: System zur energieorientierten und kostenbasierten Produktionssteuerung mittels Reinforcement Learning. Diss. TU München (2021). München.

RUSSELL & NORVIG 2010

Russell, S.; Norvig, P.: Artificial Intelligence - A Modern Approach. 3. Aufl. Upper Saddle River: Pearson Education 2010. ISBN: 978-0-13604-259-4.

SABMANNSHAUSEN 2019

Saßmannshausen, T.: Vertrauen in Entscheidungen künstlicher Intelligenz im Produktionsmanagement -

eine empirische Analyse. Düren: Shaker 2019. ISBN: 978-3-84406-757-6. (Wirtschaftswissenschaftliches Forum der FOM Band 59).

SCHMIDT & NYHUIS 2021a

Schmidt, M.; Nyhuis, P. (Hrsg.): Produktionsplanung und -steuerung im Hannoveraner Lieferkettenmodell: Innerbetrieblicher Abgleich logistischer Zielgrößen. Heidelberg: Springer Heidelberg 2021. ISBN: 978-3-66263-896-5.

SCHMIDT & NYHUIS 2021b

Schmidt, M.; Nyhuis, P.: Das Hannoveraner Lieferkettenmodell. In: Schmidt, M. et al. (Hrsg.): Produktionsplanung und -steuerung im Hannoveraner Lieferkettenmodell: Innerbetrieblicher Abgleich logistischer Zielgrößen. Heidelberg: Springer Heidelberg 2021, S. 7-26. ISBN: 978-3-66263-896-5.

SCHMIDT & NYHUIS 2021c

Schmidt, M.; Nyhuis, P.: Standardisierte Beschreibung der PPS-Aufgaben. In: Schmidt, M. et al. (Hrsg.): Produktionsplanung und -steuerung im Hannoveraner Lieferkettenmodell: Innerbetrieblicher Abgleich logistischer Zielgrößen. Heidelberg: Springer Heidelberg 2021, S. 165-210. ISBN: 978-3-66263-896-5.

SCHMIDTKE 1976

Schmidtke, H.: Ergonomische Bewertung von Arbeitssystemen - Entwurf eines Verfahrens. 1. Aufl. München: Carl Hanser 1976. ISBN: 978-3-44612-328-1.

SCHOLZ-REITER & FREITAG 2007

Scholz-Reiter, B.; Freitag, M.: Autonomous Processes in Assembly Systems. CIRP Annals 56 (2007) 2, S. 712-729.

SCHUH 2015

Schuh, G. (Hrsg.): ProSense - Hochauflösende Produktionssteuerung auf Basis kybernetischer Unterstützungssysteme und intelligenter Sensorik. 1. Aufl. Aachen: Apprimus 2015. ISBN: 978-3-86359-346-9.

SCHUH & STICH 2012

Schuh, G.; Stich, V. (Hrsg.): Produktionsplanung und -steuerung 1: Grundlagen der PPS. 4. Aufl. Berlin: Springer Vieweg 2012. ISBN: 978-3-64225-422-2. (Produktionsplanung und -steuerung 1).

SCHUH ET AL. 2017

Schuh, G.; Anderl, R.; Gausemeier, J.; ten Hompel, M.; Wahlster, W.: Industrie 4.0 Maturity Index - Die digitale Transformation von Unternehmen gestalten. München: Utz 2017. ISBN: 978-3-83164-611-1.

SCHUH ET AL. 2012a

Schuh, G.; Brandenburg, U.; Cuberq, S.: Aufgaben. In: Schuh, G. et al. (Hrsg.): Produktionsplanung und -steuerung 1: Grundlagen der PPS. 4. Aufl. Berlin: Springer Vieweg 2012, S. 29-81. ISBN: 978-3-64225-422-2. (Produktionsplanung und -steuerung 1).

SCHUH ET AL. 2012b

Schuh, G.; Brosze, T.; Brandenburg, U.; Cuber, S.; Schenk, M.; Quick, J.; Schmidt, C.; Helmig, J.; Schürmeyer, M.; Hering, N.: Grundlagen der Produktionsplanung und -steuerung. In: Schuh, G. et al. (Hrsg.): Produktionsplanung und -steuerung 1: Grundlagen der PPS. 4. Aufl. Berlin: Springer Vieweg 2012, S. 11-293. ISBN: 978-3-64225-422-2. (Produktionsplanung und -steuerung 1).

SCHUH ET AL. 2014

Schuh, G.; Potente, T.; Thomas, C.; Hauptvogel, A.: Steigerung der Kollaborationsproduktivität durch cyber-physische Systeme. In: Bauernhansl, T. et al. (Hrsg.): Industrie 4.0 in Produktion, Automatisierung und Logistik. Wiesbaden: Springer Fachmedien Wiesbaden 2014, S. 277-295. ISBN: 978-3-65804-681-1.

SCHUH ET AL. 2019

Schuh, G.; Reinhart, G.; Prote, J.-P.; Sauer mann, F.; Horsthofer, J.; Oppolzer, F.; Knoll, D.: Data Mining Definitions and Applications for the Management of Production Complexity. Procedia CIRP 81 (2019), S. 874-879.

SCHUH ET AL. 2015

Schuh, G.; Reuter, C.; Hauptvogel, A.; Brambring, F.; Hempel, T.: Einleitung. In: Schuh, G. (Hrsg.): ProSense. Hochauflösende Produktionssteuerung auf Basis kybernetischer Unterstützungssysteme und intelligenter Sensorik. 1. Aufl. Aachen: Apprimus 2015, S. 1-14. ISBN: 978-3-86359-346-9.

SCHULMAN ET AL. 2017

Schulman, J.; Wolski, F.; Dhariwal, P.; Radford, A.; Klimov, O.: Proximal Policy Optimization Algorithms. <<https://doi.org/10.48550/arXiv.1707.06347>>.

SHAPLEY 1953

Shapley, L.: A Value for n-Person Games. In: Kuhn, H. W. et al. (Hrsg.): Contributions to the Theory of Games II. Princeton: Princeton University Press 1953, S. 307-317.

SHERMAN ET AL. 2014

Sherman, J.; Gawronski, B.; Trope, Y. (Hrsg.): Dual-Process Theories of the Social Mind. New York: New York: Guilford Publications 2014. ISBN: 978-1-46251-439-7.

SHLEIFER 2012

Shleifer, A.: Psychologists at the Gate: A Review of Daniel Kahneman's Thinking, Fast and Slow. Journal of Economic Literature 50 (2012) 4, S. 1080-1091.

SHRIKUMAR ET AL. 2017

Shrikumar, A.; Greenside, P.; Kundaje, A.: Learning important features through propagating activation differences. In: Precup, D. et al. (Hrsg.): Proceedings of the 34th International Conference on Machine Learning - Volume 70. Sydney: JMLR.org 2017, S. 3145-3153.

STANOVICH & WEST 2000

Stanovich, K.; West, R.: Individual differences in reasoning: implications for the rationality debate? The Behavioral and brain sciences 23 (2000) 5, 645-665.

STANOVICH ET AL. 2014

Stanovich, K.; West, R.; Toplak, M.: Rationality, Intelligence, and the Defining Features. In: Sherman, J. W. et al. (Hrsg.): Dual-Process Theories of the Social Mind. New York: New York: Guilford Publications 2014. ISBN: 978-1-46251-439-7.

STEELS 1995

Steels, L. (Hrsg.): The Biology and Technology of Intelligent Autonomous Agents. Berlin, Heidelberg: Springer Berlin Heidelberg 1995. ISBN: 978-3-64279-631-9.

STEINLEIN ET AL. 2020

Steinlein, F.; Liu, Y.; Stich, V.: Development of a decision support app for short term production control to improve the adherence to delivery dates. In: Nyhuis, P. et al. (Hrsg.): Proceedings of the 1st Conference on Production Systems and Logistics (CPSL 2020). Hannover: publish-Ing. 2020.

SUTTON & BARTO 2018

Sutton, R.; Barto, A.: Reinforcement learning: - an introduction. Cambridge: The MIT Press 2018. ISBN: 978-0-26203-924-6. (Adaptive computation and machine learning).

THEUMER ET AL. 2022

Theumer, P.; Edenhofner, F.; Zimmermann, R.; Zipfel, A.: Explainable Deep Reinforcement Learning for Production Control. In: Herberger, D. et al. (Hrsg.): Proceedings of the Conference on Production Systems and Logistics: CPSL 2022. Hannover: publish-Ing. 2022, S. 809-818.

THRUN ET AL. 2003

Thrun, S.: Advances in Neural Information Processing Systems 16. Cambridge: MIT Press 2003. ISBN: 978-0-26220-152-0.

TRIST 1981

Trist, E.: The evolution of socio-technical systems - A conceptual framework and an action research program. Toronto: Ontario Ministry of Labour, Ontario Quality of Working Life Centre 1981. ISBN: 978-0-77436-286-3. (Occasional paper no. 2,).

TRZYNA 2015

Trzyna, D.: Modellierung und Steuerung von Eilaufträgen in der Produktion. Diss. Technische Universität Hamburg-Harburg (2015). Hamburg.

TVERSKY & KAHNEMAN 1974

Tversky, A.; Kahneman, D.: Judgment under Uncertainty: Heuristics and Biases. Science (New York, N.Y.) 185 (1974) 4157, S. 1124-1131.

ULRICH & HILL 1976

Ulrich, P.; Hill, W.: Wissenschaftstheoretische Grundlagen der Betriebswirtschaftslehre (Teil I). Wirtschaftswissenschaftliches Studium: Zeitschrift für Ausbildung und Hochschulkontakt 5 (1976) 7+8, S. 304-309.

VASSILYEV ET AL. 2013

Vassilyev, S.; Novikov, D.; Bakhtadze, N.: Intelligent Control of Industrial Processes. IFAC Proceedings Volumes 46 (2013) 9, S. 49-57.

VDI 1992

VDI: Lexikon der Produktionsplanung und -steuerung - Begriffszusammenhänge und Begriffsdefinitionen. VDI. 4. Aufl. Düsseldorf: VDI-Verlag 1992. ISBN: 978-3-18401-006-5.

VDI 3633-1

VDI 3633, Blatt 1: Simulation von Logistik-, Materialfluss- und Produktionssystemen - Grundlagen. Berlin: Beuth 2014.

VDI 5600-1

VDI 5600, Blatt 1: Fertigungsmanagementsysteme - Manufacturing Execution Systems - MES. Berlin: Beuth 2016.

VDI WISSENSFORUM GMBH 2018

VDI WISSENSFORUM GMBH: Automation 2018-1. Auflage. Düsseldorf: VDI-Verlag 2018. ISBN: 978-3-18102-330-3. (VDI-Berichte 2330).

VDI/VDE 2653-2

VDI/VDE 2653, Blatt 2: Agentensysteme in der Automatisierungstechnik - Entwicklung. Berlin: Beuth 2018.

VDI/VDE 2653-1

VDI/VDE 2653, Blatt 1: Agentensysteme in der Automatisierungstechnik - Grundlagen. Düsseldorf: VDI/VDE-Richtlinien 2018.

VDI/VDE 2653-4

VDI/VDE 2653, Blatt 4: Agentensysteme in der Automatisierungstechnik - Ausgewählte Muster für die Feldebene und Energiesysteme: 2022.

VERNIM ET AL. 2014

Vernim, S.; Hees, A.; Teschemacher, U.; Wagner, M.; Reinhart, G.: Produktionsplanung und -steuerung mittels bionischem Scheduler. Zeitschrift für wirtschaftlichen Fabrikbetrieb 109 (2014) 12, S. 915-919.

VOGEL-HEUSER ET AL. 2015

Vogel-Heuser, B.; Göhner, P.; Lüder, A.: Agent-Based Control of Production Systems—and Its Architectural Challenges. In: Leitão, P. et al. (Hrsg.): Industrial Agents. Emerging Applications of Software Agents in Industry. Boston: Elsevier 2015, S. 153-170. ISBN: 978-0-12800-341-1.

VOGEL-HEUSER ET AL. 2018

Vogel-Heuser, B.; Ryashentseva, D.; Salazar Cruz, L.; Ocker, F.; Hoffmann, M.; Brehm, R.; Bruce-Boye, C.; Redder, M.; Lüder, A.: Agentenmuster für flexible und rekonfigurierbare Industrie 4.0/CPS- Automatisierungsbzw. Energiesysteme. In: VDI Wissensforum GmbH (Hrsg.): Automation 2018. 1. Auflage Aufl. Düsseldorf: VDI-Verlag 2018, S. 1119-1130. ISBN: 978-3-18102-330-3. (VDI-Berichte 2330).

VOM BROCKE 2015

vom Brocke, J.: Referenzmodellierung. Diss. Westfälische Wilhelms-Universität Münster (2015). Münster.

WACHTER ET AL. 2018

Wachter, S.; Mittelstadt, B.; Russell, C.: Counterfactual explanations without opening the black box: automated decisions and the GDPR. Harvard Journal of Law and Technology 31 (2018) 2, S. 841-887.

WANG ET AL. 2022

Wang, D.; Qiao, F.; Guan, L.; Liu, J.; Ding, C.: Human–Machine Collaborative Decision-Making Method Based on Confidence for Smart Workshop Dynamic Scheduling. IEEE Robotics and Automation Letters 7 (2022) 3, S. 7850-7857.

WANG ET AL. 2020

Wang, D.; Qiao, F.; Wang, J.; Liu, J.; Kong, W.: Human-Machine Cooperation Based Adaptive Scheduling for a Smart Shop Floor. In: IEEE (Hrsg.): 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Toronto: IEEE 2020, S. 788-793. ISBN: 978-1-72818-526-2.

WANG ET AL. 2019

Wang, D.; Yang, Q.; Abdul, A.; Lim, B.: Designing Theory-Driven User-Centric Explainable AI. In: Brewster, S. et al. (Hrsg.): Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems, CHI '19: CHI Conference on Human Factors in Computing Systems. Glasgow. New York: ACM 2019, S. 1-15. ISBN: 978-1-45035-970-2.

WANG ET AL. 2018

Wang, J.; Ma, Y.; Zhang, L.; Gao, R.; Wu, D.: Deep learning for smart manufacturing: Methods and applications. Journal of manufacturing systems 48 (2018), S. 144-156.

WASCHNECK 2020

Waschneck, B.: Autonome Entscheidungsfindung in der Produktionssteuerung komplexer Werkstattfertigungen. Diss Universität Stuttgart (2020). Stuttgart.

WASCHNECK ET AL. 2018

Waschneck, B.; Reichstaller, A.; Belzner, L.; Altenmüller, T.; Bauernhansl, T.; Knapp, A.; Kyek, A.: Optimization of global production scheduling with deep reinforcement learning. Procedia CIRP 72 (2018), S. 1264-1269.

WASCHULL ET AL. 2020

Waschull, S.; Bokhorst, J.; Molleman, E.; Wortmann, J.: Work design in future industrial production: Transforming towards cyber-physical systems. Computers & Industrial Engineering 139 (2020), S. 105679.

WEBER & KABST 2006

Weber, W.; Kabst, R.: Einführung in die Betriebswirtschaftslehre. 6. Aufl. Wiesbaden: Gabler 2006. ISBN: 978-3-834-99072-3. (Springer eBook Collection Business and Economics).

WEISS 1999

Weiss, G. (Hrsg.): Multiagent systems - A modern approach to distributed artificial intelligence. Cambridge: MIT Press 1999. ISBN: 978-0-26223-203-6.

WEIß 1995

Weiß, G.: Distributed Reinforcement Learning. In: Steels, L. (Hrsg.): The Biology and Technology of Intelligent Autonomous Agents. Berlin, Heidelberg: Springer Berlin Heidelberg 1995, S. 415-428. ISBN: 978-3-64279-631-9.

WENZEL ET AL. 2017

Wenzel, K.; Singer, A.; Struwe, S.; Lutze, T.: Modulare Assistenzsysteme für heterogene Produktionsumgebungen – CyProAssist. Zeitschrift für wirtschaftlichen Fabrikbetrieb 112 (2017) 3, S. 177-181.

WIENDAHL 2008

Wiendahl, H.-H.: Stolpersteine der PPS – ein sozio-technischer Ansatz für das industrielle Auftragsmanagement. In: Nyhuis, P. (Hrsg.): Beiträge zu einer Theorie der Logistik. Berlin, Heidelberg: Springer Berlin Heidelberg 2008. ISBN: 978-3-54075-642-2.

WIENDAHL 2011

Wiendahl, H.-H.: Auftragsmanagement der industriellen Produktion Grundlagen, Konfiguration, Einführung. Heidelberg: Springer Heidelberg 2011. ISBN: 978-3-64219-148-0. (VDI-Buch).

WIENDAHL ET AL. 2007

Wiendahl, H.-P.; ElMaraghy, H.; Nyhuis, P.; Zäh, M.; Wiendahl, H.-H.; Duffie, N.; Brieke, M.: Changeable Manufacturing - Classification, Design and Operation. CIRP Annals 56 (2007) 2, S. 783-809.

WIENDAHL & WIENDAHL 2019

Wiendahl, H.-P.; Wiendahl, H.-H.: Betriebsorganisation für Ingenieure. München: Carl Hanser 2019. ISBN: 978-3-44644-661-8.

WILDEMANN 2009

Wildemann, H.: Variantenmanagement - Leitfaden zur Komplexitätsreduzierung, -beherrschung und -vermeidung in Produkt und Prozess. München: TCW-Verlag 2009. ISBN: 978-3-92991-817-5. (Leitfaden / TCW Transfer-Centrum für Produktionslogistik und Technologie-Management 5).

WISCHMANN & HARTMANN 2018

Wischmann, S.; Hartmann, E. (Hrsg.): Zukunft der Arbeit - Eine praxisnahe Betrachtung. Berlin: Springer Vieweg 2018. ISBN: 978-3-66249-266-6.

WISCHMANN & HARTMANN 2018a

Wischmann, S.; Hartmann, E.: Zukunft der Arbeit in Industrie 4.0 – Szenarien aus Forschungs- und Entwicklungsprojekten. In: Wischmann, S. et al. (Hrsg.): Zukunft der Arbeit. Eine praxisnahe Betrachtung. Berlin: Springer Vieweg 2018, S. 1-7. ISBN: 978-3-66249-266-6.

WISCHMANN & HARTMANN 2018b

Wischmann, S.; Hartmann, E.: Prognostizierte Veränderungen der gestaltbaren Arbeitssystemdimensionen. In: Wischmann, S. et al. (Hrsg.): Zukunft der Arbeit. Eine praxisnahe Betrachtung. Berlin: Springer Vieweg 2018. ISBN: 978-3-66249-266-6.

WITTEN ET AL. 2011

Witten, I.; Frank, E.; Hall, M. (Hrsg.): Data Mining: Practical Machine Learning Tools and Techniques (Third Edition). 3. Aufl. Boston: Morgan Kaufmann 2011. ISBN: 978-0-12374-856-0. (The Morgan Kaufmann Series in Data Management Systems).

WITTEN ET AL. 2011

Witten, I.; Frank, E.; Hall, M.: Chapter 10 - Introduction to Weka. In: Witten, I. H. et al. (Hrsg.): Data Mining: Practical Machine Learning Tools and Techniques (Third Edition). 3. Aufl. Boston: Morgan Kaufmann 2011, S. 403-406. ISBN: 978-0-12374-856-0. (The Morgan Kaufmann Series in Data Management Systems).

WOLF ET AL. 2018

Wolf, S.; Dollinger, C.; Hees, A.; Reinhart, G.: Der Mensch in Interaktion mit autonomen Planungs- und Steuerungssystemen für Cyber-Physische Produktionssysteme. In: Wischmann, S. et al. (Hrsg.): Zukunft der Arbeit. Eine praxisnahe Betrachtung. Berlin: Springer Vieweg 2018, S. 123-132. ISBN: 978-3-66249-266-6.

WOOLDRIDGE 1999

Wooldridge, M.: Intelligent Agents. In: Weiss, G. (Hrsg.): Multiagent systems. A modern approach to distributed artificial intelligence. Cambridge: MIT Press 1999, S. 3-51. ISBN: 978-0-26223-203-6.

YIN ET AL. 2019

Yin, M.; Wortman Vaughan, J.; Wallach, H.: Understanding the Effect of Accuracy on Trust in Machine Learning Models. In: Brewster, S. et al. (Hrsg.): Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems, CHI '19: CHI Conference on Human Factors in Computing Systems. Glasgow. New York: ACM 2019, S. 1-12. ISBN: 978-1-45035-970-2.

YU ET AL. 2017

Yu, K.; Berkovsky, S.; Taib, R.; Conway, D.; Zhou, J.; Chen, F.: User Trust Dynamics. In: Papadopoulos, G. A. et al. (Hrsg.): IUI'17, IUI'17: 22nd International Conference on Intelligent User Interfaces. Limassol Cyprus. New York, New York: The Association for Computing Machinery 2017, S. 307-317. ISBN: 978-1-45034-348-0.

ZEDNIK 2021

Zednik, C.: Solving the Black Box Problem: A Normative Framework for Explainable Artificial Intelligence. Philosophy & Technology 34 (2021) 2, S. 265-288.

ZHANG & YU 2020

Zhang, H.; Yu, T.: Taxonomy of Reinforcement Learning Algorithms. In: Dong, H. et al. (Hrsg.): Deep Reinforcement Learning. Singapore: Springer Singapore 2020, S. 125-133. ISBN: 978-9-81154-094-3.

ZIMMERMANN 2023

Zimmermann, R.: Erklärbares Deep Reinforcement Learning im Kontext der Produktionssteuerung. Masterarbeit. Lehrstuhl für Produktionsinformatik, Universität Augsburg (2023). Augsburg.

ZIPFEL 2023

Zipfel, A.: Anreizbasierter Austausch für die Produktionssteuerung relevanter Informationen in Wertschöpfungsnetzwerken. Diss. Technische Universität München (2023). München.

ZIPFEL ET AL. 2021

Zipfel, A.; Herdeg, D.; Theumer, P.: Method for quantifying the value of information for production control in cross-company value-adding networks. *Procedia Manufacturing* 54 (2021), S. 1-6.

11 Betreute Studienarbeiten

Im Rahmen dieser Dissertation entstanden am Institut für Werkzeugmaschinen und Betriebswissenschaften (*iwb*) der Technischen Universität München (TUM) sowie am Fraunhofer-Institut für Gießerei-, Composite- und Verarbeitungstechnik (IGCV) in den Jahren 2018 bis 2023 unter wesentlicher wissenschaftlicher, fachlicher und inhaltlicher Anleitung des Autors die im Folgenden aufgeführten studentischen Arbeiten. In diesen wurden unter anderem Fragestellungen zu einem lernenden und erklärbaren System zur Entscheidungsunterstützung in der Produktionssteuerung untersucht. Entstandene Ergebnisse sind teilweise in das vorliegende Dokument eingeflossen. Der Autor dankt allen Studierenden für ihr Engagement bei der Unterstützung dieser wissenschaftlichen Arbeit. Im Folgenden sind die Studienarbeiten in alphabetischer Reihenfolge des Nachnamens der Autoren aufgeführt.

- Brecht, Matthias: Entwicklung eines intelligenten, situativen Systems zur Entscheidungsunterstützung in der Produktionssteuerung (Masterarbeit, Technische Universität München, Kapitel 4)
- Edenhofner, Florian: Intelligente Produktionssteuerung zur Reduktion von Lebensmittelverschwendung (Masterarbeit, Technische Universität München, Kapitel 5)
- Erber, Fabian: Reaktion auf unvorhergesehene Ereignisse mittels Reinforcement Learning im Kontext der Produktionssteuerung (Masterarbeit, Universität Augsburg, Kapitel 5, 7 und 14.3.1)
- Hörmann, Bruno: Entscheidungsunterstützung in der Produktionssteuerung mittels Erklärbarem Reinforcement Learning (Masterarbeit, Technische Universität München, Kapitel 5 und 6)
- Kruse, Sibelius: User-Centric Explainable Deep Reinforcement Learning for Decision Support Systems (Bachelorarbeit, Philipps-Universität Marburg, Kapitel 4 und 7)
- Linder, Thomas: Erklärbares Multiagenten Reinforcement Learning als Entscheidungsunterstützung in der Produktion (Bachelorarbeit, Hochschule Augsburg, Kapitel 6 und 7)
- Maag, Fabian: Reward Design für Multiagent-Deep-Reinforcement-Learning im Kontext der Produktionssteuerung (Masterarbeit, Hochschule Ansbach, Kapitel 7)

- Meyl, Johannes: Entwicklung einer intelligenten und situationsbasierten Produktionssteuerung unter Berücksichtigung von Methoden der Künstlichen Intelligenz (Masterarbeit, Technische Universität München, Kapitel 5)
- Rauch, Ann-Kathrin: Künstliche Intelligenz zur effizienten Nutzung von Ressourcen in der Produktion (Masterarbeit, Technische Universität München, Kapitel 6)
- Zimmermann, Roland: Erklärbares Deep Reinforcement Learning im Kontext der Produktionssteuerung (Masterarbeit, Universität Augsburg, Kapitel 6, 7 und 14.3.2)

12 **Abbildungsverzeichnis**

Abbildung 1-1:	Häufigkeit der Übersteuerung der Planung von PPS-Systemen durch Mitarbeiter (i. A. an LÖDDING 2019)...	3
Abbildung 1-2:	Potenzial eines Systems zur Entscheidungsunterstützung in der PPS (i. A. an SCHUH ET AL. 2017, STEINLEIN ET AL. 2020).....	4
Abbildung 1-3:	Zielsetzung der Arbeit mit daraus abgeleiteten Subzielen.....	6
Abbildung 1-4:	Heuristischer Bezugsrahmen dieser Arbeit.....	8
Abbildung 1-5:	Forschungsmethodische Vorgehen nach BLESSING & CHAKRABARTI (2009)	9
Abbildung 1-6:	Aufbau der Arbeit und Einordnung in die DRM.....	10
Abbildung 2-1:	Logistische Zielsystem der Produktionsplanung und -steuerung (i. A. an WIENDAHL & WIENDAHL 2019)	13
Abbildung 2-2:	Aufgabensicht des Aachener PPS-Modells (SCHUH ET AL. 2012b).....	14
Abbildung 2-3:	Modell der Fertigungssteuerung (i. A. an LÖDDING 2016).....	16
Abbildung 2-4:	Mögliche Ausprägungen der Auftragsfreigabe (i. A. an LÖDDING 2016).....	17
Abbildung 2-5:	Zusammenhang zwischen Zeichen, Daten, Informationen und Wissen (i. A. an BODENDORF 2006)	20
Abbildung 2-6:	Charakterisierung von PPS-Systemen nach Ebene, System, Aufgabe und Zeithorizont (i. A. an KLETTI 2015a, VDI 5600-1)	21
Abbildung 2-7:	Überblick über unterschiedliche Organisationsstrukturen (i. A. an SCHOLZ-REITER & FREITAG 2007, ENGELHARDT 2015).....	22
Abbildung 2-8:	Charakteristische Eigenschaften eines Agenten	28
Abbildung 2-9:	Beschreibung unterschiedlicher Charakteristika der Umgebung eines Agentensystems mit Hilfe eines morphologischen Kastens	29

Abbildung 2-10:	Interaktion zwischen einem Agenten und seiner Umgebung in einem MEP (SUTTON & BARTO 2018) ...	32
Abbildung 2-11:	Einordnung unterschiedlicher RL-Algorithmen in eine Taxonomie für RL (i. A. an ZHANG & YU 2020)	35
Abbildung 2-12:	Kategorisierung der Ansätze von erklärbaren KI (i. A. an MURDOCH ET AL. 2019)	41
Abbildung 2-13:	Qualitativer Vergleich von opaken und transparenten Modellen. Veranschaulichung des Einflusses von Post-hoc-Verfahren auf die Erklärbarkeit von opaken Modellen. (i. A. an ADADI & BERRADA 2018)	42
Abbildung 2-14:	Veranschaulichung der Primärdeterminanten der Entscheidung (i. A. an LAUX & LIERMANN 2005)	46
Abbildung 2-15:	Klassifikation von Entscheidungsunterstützungssystemen (i. A. an POWER 2002, 2004)	48
Abbildung 3-1:	Überblick über das lernende und erklärbare System zur Entscheidungsunterstützung in der Produktionssteuerung	56
Abbildung 3-2:	Zusammenhang der definierten Kategorien der Entscheidungsunterstützung und der Partialsysteme <i>lernende benutzerrollenspezifische Produktionssteuerung</i> und <i>Erklärbarkeit von systemischen Entscheidungen</i>	58
Abbildung 4-1:	Vorgehen zur Erstellung eines benutzerspezifischen Informationsmodells	60
Abbildung 4-2:	Morphologischer Kasten für unterschiedliche Benutzerrollen sowie deren unterschiedliche Ausprägungen	62
Abbildung 4-3:	Initiale Zuordnung der Benutzerrollen zu den Ebenen der Fabrik	64
Abbildung 4-4:	Struktur des Maßnahmenreferenzkatalogs	65
Abbildung 4-5:	Kategorien der Entscheidungsunterstützung	73
Abbildung 4-6:	Zusammenhang zwischen den definierten Kategorien der Entscheidungsunterstützung und den adressierten Defiziten der dualen Architektur der Entscheidungspsychologie	76
Abbildung 4-7:	Überblick über das benutzerrollenspezifische Referenzmodell	77

Abbildung 4-8:	Ablauf der unternehmensspezifischen Anpassung des entwickelten Referenzmodells	78
Abbildung 5-1:	Bestandteile des Agentensystems zur Realisierung der lernenden benutzerrollenspezifischen Entscheidungsunterstützung im Kontext der Produktionssteuerung	81
Abbildung 5-2:	Unified Modeling Language(UML)-Notation der Produktionsressource (i. A. an OSTGATHE 2012).....	83
Abbildung 5-3:	UML-Notation des Auftragsmodells (i. A. an LOOS 1999, OSTGATHE 2012, KLÖBER-KOCH 2021, RÖSCH 2021).....	84
Abbildung 5-4:	Merkmale zur Charakterisierung unterschiedlicher Agentenentwurfsmuster (i. A. an VOGEL-HEUSER ET AL. 2018, ECKERT ET AL. 2012 und VDI/VDE 2653-4) 87	
Abbildung 5-5:	Schematischer Aufbau eines Agentensystems in Abhängigkeit von den unterschiedlichen Aggregationsebenen eines Produktionssystems (i. A. an JENNINGS 2001, MONOSTORI ET AL. 2006).....	89
Abbildung 5-6:	Grundtypen möglicher Aktionen der Agenten im Kontext der Produktionssteuerung.....	92
Abbildung 5-7:	Beispielhafte Gestaltung unterschiedlicher Aktionen einen Agentensystems	93
Abbildung 5-8:	Ablauf der Aktionswahl durch den Agenten in Abhängigkeit von den Eingangsgrößen	95
Abbildung 5-9:	Hierarchischer Aufbau und Ablauf des Trainingsprozesses (i. A. an THEUMER ET AL. 2022) ...	96
Abbildung 5-10:	Kostenbestandteile des Systems zur Bestimmung der OPP (i. A. an ZIPFEL ET AL. 2021)	98
Abbildung 5-11:	Beispielhafter Ablauf von Curriculum Learning in einem Agentensystem inklusive spezifischer Trainingsziele.	100
Abbildung 5-12:	Ablauf der unternehmensspezifischen Anpassung der lernenden Produktionssteuerung	103
Abbildung 5-13:	Beispiel eines ausgefüllten Templates zur strukturierten Beschreibung von Agenten	104
Abbildung 5-14:	Differenzierung zwischen der Trainings- und der Anwendungsphase.....	106

Abbildung 6-1:	Idealisierter Ablauf der Entscheidungsfindung	108
Abbildung 6-2:	Charakteristika der Eignung unterschiedlicher XAI-Verfahren	109
Abbildung 6-3:	Zusammenhang von Vorhersagegenauigkeit und Beschreibungsgenauigkeit für Post-hoc-Verfahren (i. A. an MURDOCH ET AL. 2019).....	110
Abbildung 6-4:	Interaktion zwischen dem Beobachtungsraum, dem Agenten und der SHAP-Bibliothek zur Approximation der SHAP-Werte (i. A. an COOPER 2021)	113
Abbildung 6-5:	Beispielhafte Visualisierung der Bedeutung einzelner Merkmale anhand ihrer SHAP-Werte.....	115
Abbildung 6-6:	Einflussfaktoren auf eine einzelne Entscheidung (i. A. an THEUMER ET AL. 2022).....	116
Abbildung 6-7:	Definition eines Kontrafaktuals nach WACHTER ET AL. (2018) sowie die beispielhafte textuelle Ausgabe eines Kontrafaktuals	117
Abbildung 6-8:	Verknüpfung des Verfahrens zur Bestimmung der Merkmalsrelevanz mit dem Verfahren zur Generierung von Kontrafaktualen	119
Abbildung 6-9:	Ablauf der Integration von Erklärbarkeitsansätzen in das System zur Entscheidungsunterstützung	120
Abbildung 6-10:	Beispielhafte Abbildung der Rechenzeit unterschiedlicher Erklärbarkeitsansätze in Abhängigkeit von der Anzahl der Merkmale	121
Abbildung 6-11:	Interaktion zwischen dem Nutzer und dem System zur Entscheidungsunterstützung (i. A. an HÖRMANN 2022)	122
Abbildung 7-1:	Abbildung des Produktionsprozesses inkl. Systemgrenze.....	126
Abbildung 7-2:	Abbildung der betrachteten Produktionslinien	128
Abbildung 7-3:	Differenzierung der unterschiedlichen Schritte zur Systemerstellung in Abhängigkeit von der Häufigkeit der Anwendung	131
Abbildung 7-4:	Morphologischer Kasten für unterschiedliche Benutzerrollen sowie deren unterschiedliche Ausprägungen. Die Merkmale des Meisters sind hervorgehoben.	132

Abbildung 7-5:	Softwareübersicht des entwickelten Systems	135
Abbildung 7-6:	Konzeptioneller Aufbau des Agentensystems unter Berücksichtigung der unterschiedlichen Aggregationsebenen des Produktionssystems	137
Abbildung 7-7:	Ausgefülltes Template für den Agenten <i>Meister</i> der Produktionslinie 1	138
Abbildung 7-8:	Ablauf des Curriculum Learnings am Beispiel der Produktionslinie 1	139
Abbildung 7-9:	Entwicklung der OPP in Abhängigkeit vom Systemaufbau (i. A. an MAAG 2023)	140
Abbildung 7-10:	Visualisierung des resultierenden Produktionsplans für die Produktionslinie PL 1 mit Hilfe der entwickelten webbasierten Visualisierung	141
Abbildung 7-11:	Veranschaulichung der Merkmalsrelevanz mit Hilfe von SHAP-Werten (i. A. an KRUSE 2023)	142
Abbildung 7-12:	Ausgabe dreier unterschiedlicher Kontrafaktuale unter Berücksichtigung des vom Benutzer erwarteten Ergebnisses (Zuordnung der Rezeptur R55 zur Produktionsressource R 1.1.2)	143
Abbildung 7-13:	Abbildung der globalen Erklärbarkeit mit Hilfe der Visualisierung des betragsmäßigen durchschnittlichen Einflusses unterschiedlicher Merkmale auf die Auswahl einer bestimmten Aktion (Auswahl der Rezeptur R30) (i. A. an KRUSE 2023)	144
Abbildung 7-14:	Verifizierung des Simulationsmodells anhand der Anzahl der pro Woche fertiggestellten Aufträge	148
Abbildung 7-15:	Lernverhalten eines Anlagenbedieneragenten in Abhängigkeit von den Zeitschritten des Trainings	149
Abbildung 7-16:	Resultierende mittlere OPP in Abhängigkeit von den definierten Simulationsszenarien	149
Abbildung 7-17:	Durchschnittliche Rüst- und Reinigungszeit pro Episode sowie mittlere Termintreue in Abhängigkeit von den definierten Simulationsszenarien	150
Abbildung 14-1:	Ursache-Wirkungs-Matrix zur qualitativen Darstellung der Auswirkungen von Steuerungsmaßnahmen auf Kennzahlen (i. A. an PIELMEIER 2019)	193
Abbildung 14-2:	Bestimmen der Auswirkung einer unterschiedlichen Anzahl von Clustern auf die Summe der quadrierten	

	Abstände mit Hilfe der Ellenbogenmethode (i. A. an ERBER 2023).....	195
Abbildung 14-3:	Relevanz unterschiedlicher Merkmale sowie deren Wert für die Auswahl der Rezeptur R30. Unterschiedliche Beobachtungen werden in der Abbildung als Datenpunkte visualisiert.....	196
Abbildung 14-4:	Relevanz unterschiedlicher Merkmale sowie deren Wert für die Zuordnung einer Rezeptur zum Pool 3. Unterschiedliche Beobachtungen werden in der Abbildung als Datenpunkte visualisiert (i. A. an ZIMMERMANN 2023).	197

13 Tabellenverzeichnis

Tabelle 3-1:	Anforderungen an ein lernendes und erklärbares System zur Entscheidungsunterstützung in der Produktionssteuerung	54
Tabelle 4-1:	Übersicht über unterschiedliche Maßnahmen der Auftragsfreigabe, Kapazitätssteuerung und Reihenfolgebildung (i. A. an TRZYNA 2015, LÖDDING 2016, PIELMEIER 2019, WIENDAHL & WIENDAHL 2019, SCHMIDT & NYHUIS 2021c).....	66
Tabelle 4-2:	Charakteristika des System-1/System-2-Modells (STANOVICH ET AL. 2014)	69
Tabelle 4-3:	Unterschiedliche Bias, welche den Entscheidungsprozess negativ beeinflussen können	71
Tabelle 5-1:	Charakterisierung der Auftrags- und Klassensicht	91
Tabelle 5-2:	Ausgewählte Hyperparameter des PPO-Algorithmus (i. A. an OPENAI 2018)	94
Tabelle 5-3:	Charakteristische Eigenschaften von negativen Belohnungen und Action Masking im Umgang mit ungültigen Aktionen	102
Tabelle 6-1:	Bewertung unterschiedlicher Verfahren zur Generierung von Erklärungen für das von einem ML-Modell vorgeschlagene Ergebnis	110
Tabelle 7-1:	Exemplarische Verdeutlichung des Einflusses der Artikelreihenfolge auf die notwendigen Reinigungszeiten	127
Tabelle 7-2:	Parameter des Produktionssystems	129
Tabelle 7-3:	Beispielhafte Beschreibung der relevanten Maßnahmen der identifizierten Benutzerrollen im Kontext der Produktionssteuerung	133
Tabelle 7-4:	Übersicht über die notwendigen Agenten für das Gesamtsystem.....	136
Tabelle 7-5:	Unterschiedliche Simulationsszenarien unter Berücksichtigung der Art der Produktionssteuerung, der Realisierung von Erklärbarkeit sowie der angenommenen Reihenfolgedisziplin	145

Tabelle 7-6:	Übersicht über ausgewählte Techniken zur Verifizierung von Simulationen in Produktion und Logistik.....	147
Tabelle 8-1:	Einmalige Kosten zur Erstellung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung (Expertenschätzung)	156
Tabelle 8-2:	Laufenden Kosten für den Betrieb des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung (Expertenschätzung)	157
Tabelle 8-3:	Nutzen der Anwendung des lernenden und erklärbaren Systems zur Entscheidungsunterstützung in der Produktionssteuerung anhand des Anwendungsbeispiels	158

14 Anhang

14.1 Auswirkungen von Maßnahmen auf Kennzahlen

Abbildung 14-1 zeigt unterschiedliche Maßnahmen der Produktionssteuerung, die den Aufgaben der Produktionssteuerung zugeordnet sind. PIELMEIER (2019) hat die Auswirkungen der Maßnahmen mit Hilfe einer Ursache-Wirkungs-Matrix mit den Auswirkungen auf Kennzahlen qualitativ verknüpft. Hierdurch kann die Auswirkung einzelner Maßnahmen eingeschränkt werden.

		Kennzahl															
		Termin-treue	Mengen-treue	Liegezeit	Transportzeit	Dauer Auftragsfreigabe	Bearbeitungszeit	Rüstzeit	Störungsdauer	Produktionskosten	Auslastung	Ausbringung	Verfügbarkeit	Stillstandskosten	Anzahl wartende Aufträge	Umlaufbestand	Umschlaghäufigkeit
Maßnahme																	
Auftragsfreigabe	Beschränkung des Zugangs	●		●		●									●	●	●
	Änderung des Soll-Endtermins	●	●	●		●									●		
	Austausch von Aufträgen	●				●					●	●				●	●
Kapazitätsanpassung	Anpassung Bearb. Geschwindigkeit	●	●	●	●	●	●	●		●	●	●	●			●	●
	Springer	●	●	●	●		●	●	●	●		●		●		●	●
	Mehrmaschinen Bedienung	●	●	●		●		●		●	●	●	●			●	●
	Substitution	●	●	●		●					●	●	●	●		●	●
	Überlappende Fertigung	●	●	●		●					●	●				●	●
Reihenfolgebildung	Zusammenfassung von AV	●	●	●		●		●		●	●			●	●		
	Rüstopтимierung	●	●	●				●		●	●	●	●	●	●	●	●
	Vorziehen von Arbeitsvorgängen	●	●			●		●		●				●			
	Rightshifting und Jumping	●	●			●			●						●		

Legende:

- Hat eine Auswirkung
 Hat keine Auswirkung

Abbildung 14-1: Ursache-Wirkungs-Matrix zur qualitativen Darstellung der Auswirkungen von Steuerungsmaßnahmen auf Kennzahlen (i. A. an PIELMEIER 2019)

14.2 Deep SHAP

Bei Deep SHAP handelt es sich um eine auf der Berechnung von Shapley-Werten beruhende Methode zur Bestimmung der Merkmalsrelevanz. Deep SHAP ist für den Einsatz im Kontext von KNN bestimmt. Durch den Einsatz von Informationen zum verwendeten KNN kann die Rechenzeit für die Bestimmung der Merkmalsrelevanz reduziert werden. (LUNDBERG & LEE 2017) Die Approximation der SHAP-Werte erfolgt bei Deep SHAP unter Verwendung des DeepLIFT-Algorithmus (SHRIKUMAR ET AL. 2017). Dieser berechnet die Abweichung der Modellausgabe mittels

$$\sum_{i=1}^n C_{\Delta x_i \Delta o} = \Delta o \quad (12)$$

mit $C_{\Delta x_i \Delta o}$

Veränderung der Modellausgabe in Abhängigkeit von der Veränderung der Modelleingabe
Summe über alle Veränderungen der Modellausgabe in Abhängigkeit von der Veränderung der Modelleingabe

Δo

Dieser Term kann durch die Annahme zusätzlicher Randbedingungen so angepasst werden, dass er der für die Berechnung von SHAP-Werten notwendigen Form entspricht und der Beitrag einzelner Merkmale zur Modellausgabe basierend auf den Shapley-Werten berechnet werden kann. (LUNDBERG & LEE 2017) Für eine detaillierte Erklärung sei auf LUNDBERG & LEE (2017) verwiesen.

14.3 Anwendungsfall

14.3.1 Clusteranalyse mit Hilfe des k-Means-Algorithmus

Ziel der im Rahmen dieser Arbeit durchgeführten k-Means-Analyse ist die Bildung von Clustern zur Reduzierung der Anzahl der Einträge im Beobachtungsraum der Agenten. Hierdurch wurde eine Reduktion von 1240 Einträgen auf 118 Einträge erreicht. Abbildung 14-2 zeigt die Auswirkung der unterschiedlichen Anzahl von Clustern auf die Güte – repräsentiert durch die Summe der quadrierten Abstände – der korrespondierenden Anzahl der Cluster. Ab einer Anzahl von 18 Clustern konnte keine Veränderung der Summe der quadrierten Abstände mehr festgestellt werden. Deshalb wurden im Rahmen dieser Arbeit 18 Cluster zur Repräsentation der Artikel verwendet.




Abbildung 14-2: Bestimmen der Auswirkung einer unterschiedlichen Anzahl von Clustern auf die Summe der quadrierten Abstände mit Hilfe der Ellenbogenmethode (i. A. an ERBER 2023).

14.3.2 Erklärbarkeitsansätze

Im Folgenden finden sich weitere unterschiedliche mit Hilfe der SHAP-Bibliothek erzeugte Erklärungen (Abbildung 14-3 und Abbildung 14-4). Hierbei handelt es sich um globale Erklärungen, welche das prinzipielle Verhalten des Modells verdeutlichen.




Abbildung 14-3: Relevanz unterschiedlicher Merkmale sowie deren Wert für die Auswahl der Rezeptur R30. Unterschiedliche Beobachtungen werden in der Abbildung als Datenpunkte visualisiert.

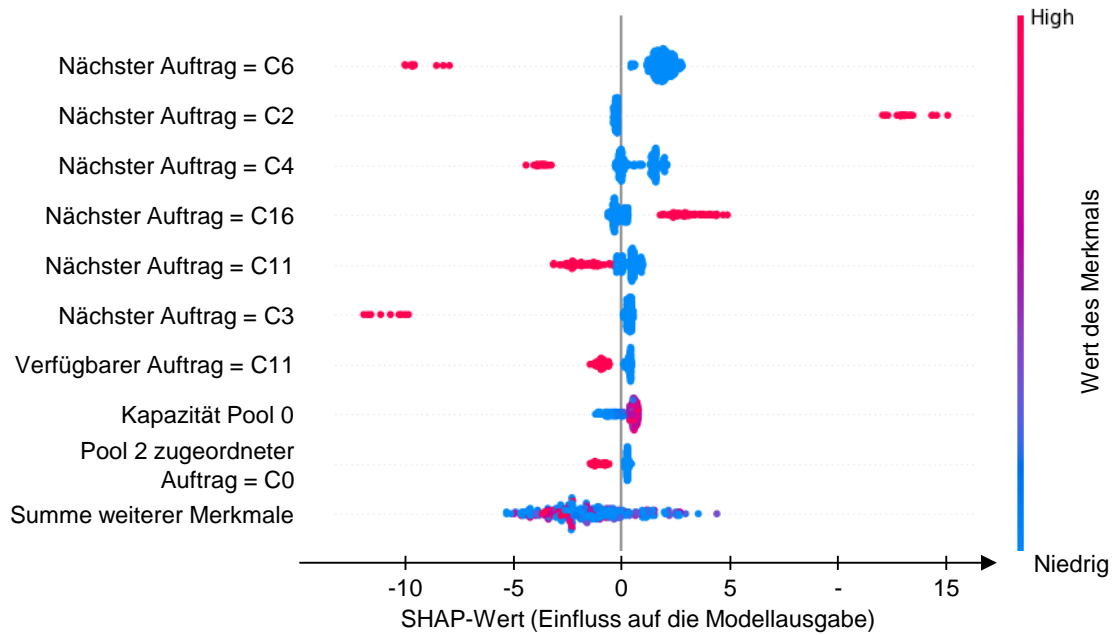


Abbildung 14-4: Relevanz unterschiedlicher Merkmale sowie deren Wert für die Zuordnung einer Rezeptur zum Pool 3. Unterschiedliche Beobachtungen werden in der Abbildung als Datenpunkte visualisiert (i. A. an ZIMMERMANN 2023).