

**Entwicklung eines Konzeptes zur selbstlernenden Fehlervermeidung  
automatisierter Montagesysteme im Anlauf  
der Fahrzeugproduktion**

**Dissertation**

zur Erlangung des akademischen Grades

**Doktoringenieurin / Doktoringenieur**

**(Dr.-Ing.)**

von M.Sc. Ralf Oliver Michael Schönherr

geb. am 08. Mai 1986 in Köln

genehmigt durch die Fakultät für Maschinenbau

der Otto-von-Guericke-Universität Magdeburg

Gutachter:

Prof. Dr. sc. techn. Ulrich Schmucker

Prof. Dr.-Ing. Udo Seiffert

Promotionskolloquium am 14.12.2018



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b> .....	<b>1</b>
1.1	Hintergrund und Motivation der Forschung	1
1.2	Zielsetzung und Aufbau der Arbeit	4
<b>2</b>	<b>Vorbetrachtung relevanter Themengebiete</b> .....	<b>7</b>
2.1	Zukünftige Automatisierung in den Teilsystemen der Fahrzeugproduktion	7
2.1.1	Automatisierungspotentiale in den Teilsystemen der Fahrzeugproduktion	7
2.1.2	Endmontage in der Automobilfließfertigung	9
2.1.3	Herausforderungen bei der Umsetzung innovativer Automatisierung in der Automobilendmontage aus Planungssicht	12
2.1.4	Aktuelle Trends und Entwicklungen der Automobilproduktion	15
2.2	Produktionsanlaufsteuerung	19
2.2.1	Allgemeines und Grundlagen	19
2.2.2	Zielgrößen des Produktionsanlaufs	24
2.2.3	Störungen im Produktionsanlauf	27
2.3	Fehlervermeidung und Fehlervorhersage in der Produktionstechnik	31
2.3.1	Regelungstechnik	31
2.3.2	Modellbasierte Verfahren	32
2.3.3	Wissensbasierte Verfahren	32
2.3.4	Exkurs maschinelle Lernverfahren	35
2.4	Zusammenfassung der Vorbetrachtungen	36

<b>3</b>	<b>Anforderung an eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage.....</b>	<b>39</b>
3.1	Allgemeines	39
3.2	Anforderungsanalyse	40
3.3	Leitsätze für eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage	43
<b>4</b>	<b>Stand der Forschung und Technik.....</b>	<b>44</b>
4.1	Überblick	44
4.2	Anlaufmanagement in der Automobilindustrie	44
4.2.1	Kennzahlorientierte Ansätze	45
4.2.2	Ansätze basierend auf Kommunikation und Informationsaustausch	48
4.2.3	Ganzheitliche Ansätze	51
4.2.4	Selbstlernende Ansätze	53
4.2.5	Zusammenfassende Betrachtung und Zwischenfazit	54
4.3	Umgang mit unvorhersehbaren Störungen im Produktionsanlauf	55
4.4	Abgrenzung vom Stand der Forschung und Technik sowie wissenschaftlicher Handlungsbedarf	59
<b>5</b>	<b>Systementwurf eines selbstlernenden automatisierten Montagesystems zur Fehlvermeidung im Produktionsanlauf .....</b>	<b>64</b>
5.1	Grundsystemarchitektur selbstlernender automatisierter Montagesysteme	65
5.2	Geeignete Algorithmen des maschinellen Lernens für die Ausgestaltung der selbstlernenden Teilkomponenten	67
5.2.1	Selbstlernende Komponente zur Fehlervorhersage	67
5.2.2	Selbstlernende Komponente zur Fehlervermeidung	73
5.3	Reduzierung hochdimensionaler Merkmalsdatenvektoren über Expertenwissen	78
5.3.1	Dimensionsreduzierung über maschinelle Verfahren	79

5.3.2	Dimensionsreduzierung mit Hilfe von Expertenwissen	81
5.4	Zusammenfassung des Systementwurfs	82
<b>6</b>	<b>Prototypische Umsetzungen, Untersuchungen und Ergebnisse.....</b>	<b>84</b>
6.1	Motivation und Übertragbarkeit des entwickelten Systementwurfs	84
6.2	Auswahl und Beschreibung eines Realprozesses - Automatisierte Montage von Verschlussstopfen	88
6.2.1	Allgemeines	88
6.2.2	Verwendeter Endeffektor	89
6.2.3	Automatisierter Montageprozess mittels sensitiver Robotik	90
6.2.4	Automatisierte Montage von Verschlussstopfen in der Serienproduktion	91
6.2.5	Störgrößen und Umfeldeinwirkungen auf den Montageprozess im Anlauf	92
6.3	Entwurf und Beschreibung des Versuchsaufbaus	95
6.3.1	Allgemeines	95
6.3.2	Datenaufnahme	96
6.4	Prototypische Konzeptumsetzung der Fehlervorhersage	108
6.4.1	Betrachteter Merkmalsdatenvektor und Datenvorverarbeitung	110
6.4.2	Unterteilung der Gesamtdatenmenge und weitere Vorbetrachtungen	112
6.5	Ergebnisse der umgesetzten Fehlervorhersage	114
6.5.1	Reduzierung des Merkmalsdatenvektors	114
6.5.2	Leistungsvergleich der identifizierten Ansätze	116
6.6	Prototypische Konzeptumsetzung der Fehlervermeidung	129
6.7	Ergebnisse der umgesetzten Fehlervermeidung	135
6.8	Fazit und Konzeptbestätigung	136
6.9	Zusammenfassung	137
<b>7</b>	<b>Validierung.....</b>	<b>139</b>
7.1	Validierung der verwendeten Versuchsdatensätze	139

7.2	Validierung der Ergebnisse	141
7.2.1	Ergebnisse der Fehlervorhersage	141
7.2.2	Ergebnisse der Fehlervermeidung	143
<b>8</b>	<b>Zusammenfassung und Ausblick .....</b>	<b>144</b>
<b>9</b>	<b>Literaturverzeichnis .....</b>	<b>148</b>
<b>10</b>	<b>Studienarbeiten .....</b>	<b>170</b>
<b>11</b>	<b>Anhang.....</b>	<b>172</b>
A:	Erhobene Versuchdaten (exklusive Bilddaten der Vorladeposition)	172
B:	Schwinungsuntersuchungen in Realumgebung	175
C:	Untersuchungen des Temperatur-Verbaukraftverhältnisses	177
D:	Vergleich Vorhersageergebnisse unterschiedlicher Datenvorskalierungen	178

# Abbildungsverzeichnis

Abbildung 1: Produktlebenszyklus früher und heute. Darstellung nach (Bischoff 2007) in Anlehnung an (Wildemann 2006) und (Burghardt 2000).....	2
Abbildung 2: Gesamtstruktur der vorliegenden Arbeit. ....	5
Abbildung 3: Teilsysteme der Fahrzeugproduktion. Eigene Darstellung in Anlehnung an (Claussen 2012; Michalos et al. 2010).....	7
Abbildung 4: Industrielle Arbeitskosten des verarbeitenden Gewerbes 2015 im internationalen Vergleich nach (Schröder 2016). ....	8
Abbildung 5: Ablaufarten der Montage nach (Schenk et al. 2014). ....	10
Abbildung 6: Verkettungsarten der mehrstufigen Fließfertigung. Darstellung nach (Lotter und Wiendahl 2012, S. 338). ....	11
Abbildung 7: Planungsmodell gemäß VDI 5200 (VDI 2011). ....	13
Abbildung 8: Ergebnisse Frage 2 Expertenbefragung Automobilendmontage des Beispielunternehmens. ....	14
Abbildung 9: Technologien Industrie 4.0 in der Automobilproduktion. Eigene Darstellung nach (Huber 2016).....	16
Abbildung 10: Erfolgsrate von Produktionsanläufen in der europäischen Automobilzulieferindustrie nach (Straube und Fitzek 2005). ....	20
Abbildung 11: Betriebsphase im Lebenszyklus von Produktionssystemen nach (Wiendahl et al. 2002). ....	21
Abbildung 12: Facetten des Anlaufmanagement. Eigene Darstellung in Anlehnung an (Schmitt 2015).....	22
Abbildung 13: Einsatzzeitraum der Anlaufsteuerung. Verallgemeinerte Darstellung nach (Fleischer et al. 2007). ....	24
Abbildung 14: Beschleunigung der Anlaufkurve und Verkürzung der „Time-to-Market“. Darstellung aus (Bischoff 2007) in Anlehnung an (Wildemann 2006; Risse 2003) erweitert um die „Time-to-Volume“ .....	25
Abbildung 15: Kostenseitige Zusatzaufwendungen/Einsparpotentiale im Anlauf nach (Weber 2002) in (Wiendahl et al. 2002).....	26
Abbildung 16: Zieldimensionen Produktionsanlauf. Darstellung aus (Peters und Hofstetter 2008) in Anlehnung an (Schneider und Lücke 2002).....	27

Abbildung 17: Anlaufhemmnisse nach (Abele et al. 2003).....	29
Abbildung 18: Abgeleiteter Störungsbegriff im Rahmen dieser Arbeit. Eigene Darstellung.....	30
Abbildung 19: Grundstruktur künstlicher neuronaler Netze in Anlehnung an (Lippe 2006, S. 51) und (Jain et al. 1996, S. 38). .....	34
Abbildung 20: Übersicht Machine Learning in Anlehnung an (Sugiyama 2015) und (Alpaydin 2014). .....	35
Abbildung 21: Existierende Ansätze Anlaufmanagement in der Automobilindustrie. Eigene und erweiterte Unterteilung basierend auf (Surbier et al. 2014).....	45
Abbildung 22: Übersicht wissenschaftlicher Ansätze zum Anlaufmanagement in der Automobilindustrie. ....	55
Abbildung 23: Übersicht wissenschaftlicher Ansätze zum Anlaufmanagement in der Automobilindustrie und Ansätze zur Störungsvermeidung im Produktionsanlauf weiterer Industrien.....	60
Abbildung 24: Existierenden wissenschaftliche Lücke und Handlungsbedarf. ....	61
Abbildung 25: Gesamtübersicht Systemarchitektur selbstlernender automatisierter Montagesysteme. ....	66
Abbildung 26: Veränderung des $\epsilon$ -Greedy-Parameters im konzeptionierten Ansatz. ....	78
Abbildung 27: Erzeugung eines aggregierten Merkmalsdatenvektors mit Hilfe von Methoden der Dimensionsreduzierung. ....	79
Abbildung 28: Kombinierte Datenverarbeitung über CNN und FCNN. ....	81
Abbildung 29: Gesamtsystemarchitektur eines selbstlernenden automatisierten Montagesystems mit Datenvorverarbeitung. ....	83
Abbildung 30: Reale Fehlerquote im ersten Produktionsanlauf des automatisierten Stopfensetzens mittels sensitiver Robotik. ....	85
Abbildung 31: Prozessstufenmodell zur prototypischen Umsetzung selbstlernender fehlvermeidender Montagesysteme im Produktionsanlauf. ....	86
Abbildung 32: Verschlussstopfen im unverbauten und verbauten Zustand. Eigene schematische Darstellung.....	88
Abbildung 33: Verwendeter Endeffektor zur automatisierten Montage von Verschlussstopfen. ....	89
Abbildung 34: Detailansicht Stopfenmagazin des verwendeten Endeffektors zur automatisierten Montage von Verschlussstopfen. ....	90
Abbildung 35: Automatisierter Montageprozess zum Setzen von Verschlussstopfen mittels sensitiver Robotik.....	91
Abbildung 36: Schematische Darstellung der Serienprozessanlage. Eigene Darstellung. ....	92
Abbildung 37: Störgrößen und Umfeldeinwirkungen der automatisierten Stopfenmontage im Anlauf. ....	93
Abbildung 38: Gesamtübersicht des Versuchsaufbaus. ....	96
Abbildung 39: Realaufbau der Versuchsanlage. ....	97
Abbildung 40: Ablaufdiagramm der Versuchsdatenerhebung. ....	98

Abbildung 41: Erfassung Stopfenhärte SHORE-Härte D.....	99
Abbildung 42: Eingabemaske manueller Messwerte.....	100
Abbildung 43: Erfassung der Stopfenoberflächentemperatur.....	101
Abbildung 44: Gewählte Perspektiven zur Bestimmung der Stopfenvorladeposition über Bilddaten.....	102
Abbildung 45: Aggregierte Bildinformationen zur Bestimmung der Stopfenvorladeposition.....	102
Abbildung 46: Fügeversuchseinrichtung zur Erfassung der Kraft- und Momentenverläufe über den Fügevorgang.....	103
Abbildung 47: Erfasste Kraft- und Momentenverläufe eines idealtypischen Fügevorgangs.....	104
Abbildung 48: XDK Sensor zur Erfassung der Lichtstärke und Raumtemperatur.....	105
Abbildung 49: Unterscheidung Rundloch zu Kragenloch.....	106
Abbildung 50: Verrastete und scheinverrastete Verschlussstopfen nach der automatisierten Montage.....	107
Abbildung 51: Eingabemaske zur Erfassung des jeweils erreichten Montageergebnisses.....	107
Abbildung 52: Datenskalierung als notwendiger Schritt der Datenvorverarbeitung.....	111
Abbildung 53: Über Expertenwissen extrahierte "relevante" Bildfeatures.....	116
Abbildung 54: Merkmalsdatenvektor Sensor- und Bilddaten.....	117
Abbildung 55: Merkmalsdatenvektor Sensordaten und Bildmerkmale.....	117
Abbildung 56: Merkmalsdatenvektor Sensordaten.....	118
Abbildung 57: Merkmalsdatenvektor Sensordaten und PCA.....	118
Abbildung 58: Konfusionsmatrizen MLP und LVQ1 über 600 Validierungsdaten bei unterschiedlicher Zusammensetzung der betrachteten Merkmalsvektoren.....	119
Abbildung 59: Konfusionsmatrizen GLVQ und SVC über 600 Validierungsdaten bei unterschiedlicher Zusammensetzung der betrachteten Merkmalsvektoren.....	120
Abbildung 60: Verlauf des mittleren quadratischen Fehlers (engl. mean squared error) über die Anzahl berechneter Epochen (engl. epochs) für einen Merkmalsdatenvektor bestehend aus Sensor- und Bilddaten.....	126
Abbildung 61: Verlauf der durchschnittlichen Genauigkeit der SVMs über die Anzahl der verwendeten Trainingsdatenpunkte für einen Merkmalsdatenvektor bestehend aus Sensordaten und PCA sowie Sensor- und Bilddaten.....	128
Abbildung 62: Verlauf der mittleren quadratischen Abweichung (engl. mean squared error) über die Anzahl berechneter Epochen (engl. epochs) für einen Merkmalsdatenvektor bestehend aus Sensordaten und PCA.....	128
Abbildung 63: Hierarchischer Aufbau der Systemkomponenten zur Fehlervermeidung.....	130
Abbildung 64: Darstellung der MODBUS-CLIENT- zu SERVER-Kommunikation.....	131
Abbildung 65: Netzarchitektur des QNN.....	132
Abbildung 66: Verwendeter Algorithmus Deep Q Learning mit iterativ fallender $\epsilon$ -Greedy-Strategie und Experience Replay.....	134

Abbildung 67: Ergebnisse der umgesetzten Fehlervermeidung in drei Szenarien. ....	136
Abbildung 68: Bestätigte Gesamtsystemarchitektur mit identifizierter algorithmischer Umsetzung. ....	137
Abbildung 69: Konfusionsmatrizen der 3-fachen Kreuzvalidierung.....	142

# Tabellenverzeichnis

Tabelle 1: Dimensionen des Störungsbegriffes. Darstellung nach (Ulrich 2016, S. 35) in Anlehnung an (Bockholt 2012, S. 42).....	28
Tabelle 2: Ableitung relevanter Messgrößen.....	94
Tabelle 3: Angewendete Algorithmen des Supervised Learning zur Fehlervorhersage.....	109
Tabelle 4. Korrelationsmatrix der identifizierten Einflussvariablen (ohne Stopfenvorladeposition). ....	113
Tabelle 5: Beschreibung der aus den Kontingenzmatrizen abgeleiteten Kennzahlen für die Beurteilung der Klassifikatoren. ....	123
Tabelle 6: Kennzahlenmatrix der erprobten Klassifikatoren. ....	124
Tabelle 7: Kennzahlenmatrix der 3-fachen Kreuzvalidierung.....	142

# Abkürzungsverzeichnis

Abb.	Abbildung
ANN	Artificial Neural Network
bzw.	beziehungsweise
CNN	Convolutional Neural Network
CPS	Cyber-physische Systeme
CPPS	Cyber-physische Produktionssysteme
DFKI	Deutsches Forschungszentrum für Künstliche Intelligenz
FMEA	Fehlermöglichkeits- und -einflussanalyse
FCNN	Fully Connected Neural Network
GLVQ	Generalized Learning Vector Quantization
GUI	Graphical User Interface
ICA	Independent Component Analysis
i. O.	in Ordnung
KI	Künstliche Intelligenz
LVQ	Learning Vector Quantization
MLP	Multi-Layer-Perzeptron
MQF	Mittlerer Quadratischer Fehler
n. i. O.	nicht in Ordnung
OEM	Original Equipment Manufacturer
OICA	Organisation Internationale des Constructeurs d'Automobiles

PCA	Principal Component Analysis (Hauptkomponentenanalyse)
RGB	Rot-Grün-Blau-Farbraum
sog.	Sogenannte(n)
SPS	Speicherprogrammierbare Steuerung
SVC	Support Vector Classification
SVM	Support Vector Machines
USB	Universal Serial Bus
u. U.	unter Umständen
VDE	Verband der Elektrotechnik, Elektronik und Informationstechnik
VDI	Verein Deutscher Ingenieure
vgl.	vergleiche
XDK	Cross Domain Development Kit
z. B.	zum Beispiel

#### Hinweise zum Verweis auf verwendete Quellen

- Eine Quellenangabe vor einem Satzzeichen bezieht sich auf den Inhalt des vorangegangenen Satzes oder Teil eines Satzes.
- Eine Quellenangabe hinter einem Satzzeichen bezieht sich auf den Inhalt des gesamten vorangegangenen Abschnittes zwischen zwei Absätze



# 1 Einleitung

## 1.1 Hintergrund und Motivation der Forschung

Das Umfeld produzierender Unternehmen ist in der heutigen Zeit geprägt durch verschiedene Einflüsse, die über sogenannte Megatrends beschrieben und erklärt werden können (vgl. Engelhardt 2015, S. 1). Diese Megatrends nehmen dabei einen indirekten oder direkten Einfluss auf die Produktionsarbeit der Zukunft. Zwei dieser Trends sind die „Durchdringung mit neuen Technologien“ sowie die „Dynamisierung der Produktlebenszyklen“ (vgl. Abele und Reinhart 2011, S. 10ff.). Im Folgenden werden die Veränderungen für das Produktionsumfeld von Automobilkonzernen anhand dieser beiden Megatrends näher diskutiert.

In der Automobilindustrie führt der technologische Wandel zu einer Dynamisierung und immer kürzeren Produktlebenszyklen bei einer gleichzeitig steigenden Variantenvielfalt durch kundenindividuelle Anpassungsmöglichkeiten. Ein Blick auf die Anzahl der angebotenen Modelle und Baureihen in der Automobilindustrie zeigt eine Vervielfachung dieser in den letzten Jahren (vgl. Diez 2015, S. 49). Weiterhin hat sich der wirtschaftliche Lebenszyklus für Produkte im Automobilssektor im Zeitraum 1980 bis 2005 von durchschnittlich 10,6 auf 6 Jahre verkürzt (vgl. Romberg und Haas 2005, S. 10ff.). Abbildung 1 verdeutlicht grafisch diese aktuellen Entwicklungen hin zu einer Verkürzung der Produktlebenszyklen.

Für Unternehmen verkürzt sich dadurch die zur Amortisation der Investitions- und Entwicklungskosten zur Verfügung stehende Zeitspanne. Um weiterhin wirtschaftlich produzieren zu können, müssen Unternehmen die Durchlaufzeiten ihrer Produkte und die notwendigen Entwicklungszeiten kontinuierlich reduzieren. Dies zeigt sich bereits heute. Während die Entwicklungszeit in der Automobilindustrie in den 1980er Jahren noch 6 Jahre betrug, beträgt diese heute durchschnittlich nur noch 4 Jahre (vgl. Bischoff 2007, S. 2).

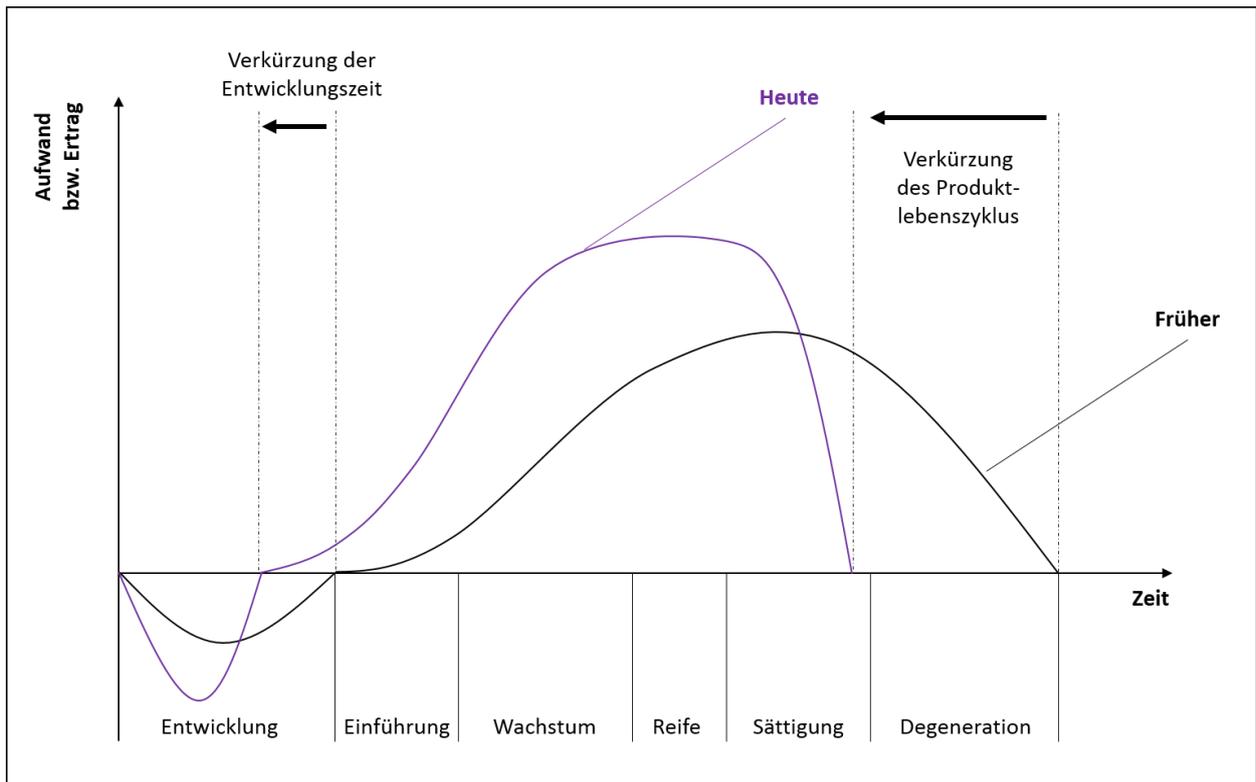


Abbildung 1: Produktlebenszyklus früher und heute. Darstellung nach (Bischoff 2007) in Anlehnung an (Wilde-  
mann 2006) und (Burghardt 2000).

Die Modellvielfalt steigt folglich kontinuierlich und Produkte ändern sich dementsprechend schneller. Dies erfordert häufigere und besonders schnelle Produktionsanläufe in der betrieblichen Praxis (vgl. Bauer et al. 2014, S. 420; Ennen et al. 2016, 57ff.), was wiederum eine der aktuellen Kernherausforderungen für die Produktionsanlaufsteuerung und das damit verbundene Fehlermanagement darstellt (vgl. Bauer et al. 2014, S. 420). Dabei bezeichnet der Produktionsanlauf die Phase zwischen dem Ende der Entwicklung und dem Erreichen der vollen Produktionskapazität eines Produktionssystems (vgl. Bohn und Terwiesch 1999, S. 47).

Gleichzeitig stehen produzierende Unternehmen heute unter dem ständigen Druck innovativ zu sein, da ihre Kunden kontinuierlich Produkte mit immer besserer Qualität und Funktionalität erwarten. Um diesem Anspruch gerecht zu werden müssen Unternehmen auf Innovationsfähigkeit hinsichtlich ihrer Produkte, aber auch ihrer Prozesse setzen, was zu einer Durchdringung neuer Technologien führt. (vgl. Schuh et al. 2005, S. 256)

Diese geforderte Innovationsfähigkeit kann dabei bedeuten, dass eine neuartige Produktionstechnologie implementiert werden muss und ein rein prozesseitig getriebener Produktionsanlauf notwendig wird (vgl. Glock et al. 2012, 1ff.).

Nach Basse et al. (2014) ist das Verhalten des Produktionssystems während des Anlaufs nicht vorhersagbar, da bestimmte Situationen das erste Mal auftreten (vgl. Basse et al. 2014, S. 94). In automatisierten Bereichen kann dies zu Ausnahmesituationen führen, welche den Anlauf unterbrechen (vgl. Ennen et al. 2016, S. 57) und eine Anpassung des Systems erfordern (vgl. Brecher et al. 2011, S. 919ff.).

Besonders beim Einsatz einer neuen Produktionstechnologie sind häufig nicht alle Wirkzusammenhänge verstanden, und in der Umsetzung innovativer Technologie liegt häufig ein zusätzliches unbekanntes Risiko durch mögliche Ausfälle. Nach Almgren (1999) kann die Integration von Produktionstechnologien zu einem zeitlich verlängerten Anlaufprozess führen. Die eigentliche angestrebte Verbesserung der Produktionstechnologie kann dabei durch die auftretenden Anlaufverluste kompensiert werden (vgl. Almgren 1999, S. 128ff.).

Diverse nationale und internationale Studien belegen, dass bei Anläufen eines Produktionssystems ein Großteil der Unternehmen ihre wirtschaftlichen und technischen Anlaufziele nicht erreichen (vgl. Straube und Fitzek 2005; Meier und Hormuth 2006; Bischoff 2007).

Ein Grund dafür sind auftretende Störeinflüsse. Im Anlaufprozess entstehen und wirken oftmals Störeinflüsse, die nicht in vorgelagerten Prozessen vorhergesehen oder verhindert werden können. Hier zeigt sich besonders beim Einsatz neuer Technologien im Sondermaschinenbau häufig erst unter Dauerlast und bei großen Stückzahlen, ob eine ausreichende Prozessreife vorhanden ist. Zu diesen internen Störeinflüssen kommen zusätzlich externe Störeinflüsse, welche sowohl in vorgelagerten als auch in zeitparallelen Prozessen entstehen. Weiterhin gilt: „Je höher der Automatisierungsgrad, desto höher die Komplexität, der Aufwand und das Risiko einer Erst- und Wiederinbetriebnahme und der dazugehörigen Hochlaufphase“. (vgl. Wiendahl et al. 2002, S. 652–654)

Basierend auf einer durchgeführten Expertenbefragung bei einem namhaften deutschen Automobilhersteller scheinen für neuartige roboterbasierte Montageanlagen dabei besonders Veränderungen der externen Prozesseinflussfaktoren eine negative Rolle zu spielen. Neue Anlagentechnik wird meist nur unter sehr konsistenten und einheitlichen Bedingungen abgesichert. Eine natürliche Variation dieser Bedingungen beim Anlauf unter Serienbedingungen kann sich dabei negativ auf die Systemperformance auswirken und zu Anlagenstillständen führen (vgl. Keller und Schönherr 2017, S. 4).

Aufgrund der meist vorherrschenden starren Verkettung der einzelnen Produktionsabschnitte zueinander (vgl. Kapitel 2.1) wirken sich in der Automobilendmontage derartige Anlagenstillstände schon nach kürzester Zeit negativ auf die tägliche Ausbringungsmenge eines Fahrzeugwerkes aus und führen damit unmittelbar zu finanziellen Verlusten für das Unternehmen.

Der Produktionsanlauf stellt in der Theorie zwar eine Ausnahmesituation im Betriebszyklus dar. In der Realität wird dieser Ausnahmezustand aufgrund der beschriebenen Entwicklungen jedoch immer mehr zu einem Standardprozess, dessen technische und wirtschaftliche Beherrschbarkeit von höchster Relevanz für Unternehmen ist (vgl. Wildemann 2004, S. 18; Schuh et al. 2008, S. 55). Umso mehr müssen damit Lösungen für die Beherrschung der Herausforderungen im Anlaufprozess gefunden werden.

Zur Motivation dieser Arbeit kann zusammenfassend festgehalten werden, dass aufgrund

- der zunehmenden Verkürzung von Produktlebenszyklen und der damit kürzeren zur Verfügung stehenden Zeitspanne zur Amortisation der Entwicklungs- und Investitionskosten,
- einer steigenden Modell- und Variantenvielfalt in der Automobilindustrie,
- der kundenseitigen Forderungen nach einer Durchdringung mit immer wieder neuen Technologien und
- existierender Risiken von Anlagenstillständen im Anlauf bedingt durch unvorhergesehene Störeinflüsse,

ein zunehmender Bedarf zur aktiven Beherrschung von Produktionsanläufen in der industriellen Praxis besteht. Besonders im Kontext neuartiger roboterbasierter Montageanlagen in der Automobilfertigung existiert ein Bedarf zur möglichst aufwandsarmen Reduzierung und Vermeidung von Anlaufverlusten, welche durch eine Schwankung der Umfeldbedingungen ausgelöst werden.

## 1.2 Zielsetzung und Aufbau der Arbeit

Eine mögliche Antwort auf die in Kapitel 1.1 genannten Herausforderungen besteht in der eigenständigen und flexiblen Anpassung der automatisierten Produktionstechnologie zur Vermeidung von anlaufbezogenen Ausfällen und Fehlern. Zielsetzung dieser Arbeit ist die Entwicklung und Erprobung eines solchen Konzeptes an einem konkreten Beispiel innovativer roboterbasierter Anlagentechnik aus der betrieblichen Praxis der Automobilendmontage zur

Lösung existierender Herausforderungen in der An- und Hochlaufphase innovativer Produktionstechnologie. Der Fokus liegt dabei auf der Vorhersage und Vermeidung von Montagefehlern im Produktionsanlauf, welche über Veränderungen der externen Prozesseinflussfaktoren ausgelöst werden. Dafür müssen zunächst die relevanten Einflussfaktoren identifiziert sowie ein zielführendes Vorhersagemodell entwickelt werden. Anschließend wird eine Validierung der erarbeiteten Methodik an einer Versuchsanlage durchgeführt.

Die vorliegende Arbeit untergliedert sich in 8 strukturgebende Kapitel. Abbildung 2 gibt einen Überblick über den gesamten Ordnungsrahmen dieser Arbeit.

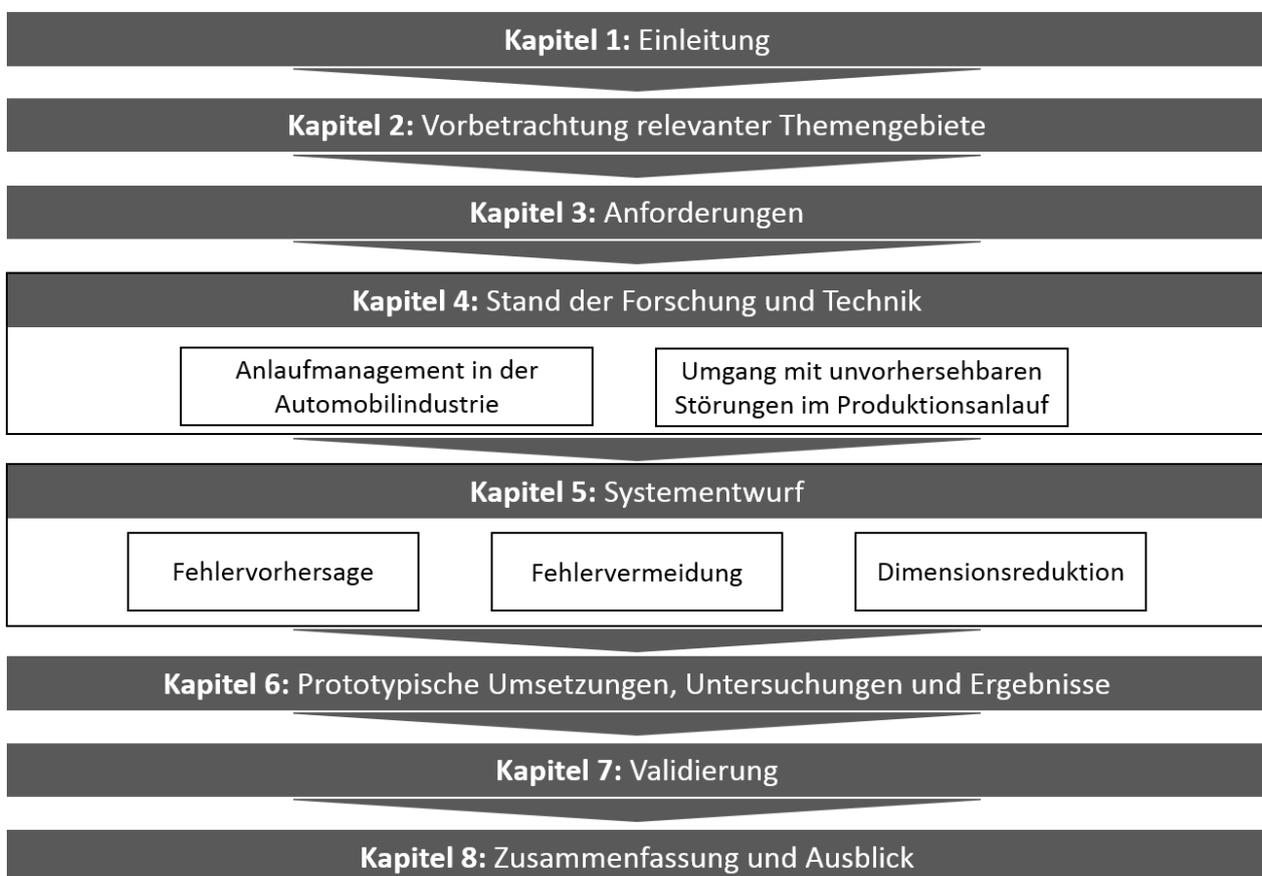


Abbildung 2: Gesamtstruktur der vorliegenden Arbeit.

Zu Beginn der Arbeit wird eine Betrachtung relevanter Themengebiete dargestellt. In Kapitel 2 erfolgt ein Einblick in die aktuellen Strukturen der Automobilendmontage. Aufgrund aktueller gesellschaftspolitischer und technologischer Entwicklungen wird die wahrscheinliche Zunahme der Automatisierungsrate in diesem Bereich aufgezeigt und die mit dieser Zunahme verbundenen Herausforderungen aus Planungssicht diskutiert. Im Anschluss wird auf die Grundlagen der Produktionsanlaufsteuerung sowie auf die damit verbundenen Zielsetzungen produzierender Unternehmen näher eingegangen. Kapitel 2 schließt mit der Diskussion

aktuell existierender Ansätze und Möglichkeiten zur Fehlervorhersage und Fehlervermeidung in automatisierter Produktionstechnik.

In Kapitel 3 werden die Anforderungen an eine zeitgemäße Anlaufsteuerung von roboterbasierten Automatisierungsanlagen für die Automobilendmontage aus den Vorbetrachtungen und Zielsetzungen abgeleitet. Die sich dabei aus der Anforderungsanalyse ergebenden Eigenschaften werden durch die Formulierung von Leitsätzen konkretisiert und ergänzt.

Über einen Einstieg in den aktuellen Stand der wissenschaftlichen Forschung und Technik wird anschließend in Kapitel 4 der Handlungsbedarf abgeleitet. Dabei wird auf die existierende Lücke zwischen Anlaufmanagement und Störungsvermeidung genauer eingegangen.

Zur zielgerichteten Erfüllung des identifizierten Handlungsbedarfes erfolgt im nachfolgenden Kapitel 5 der Konzeptentwurf einer selbstlernenden Fehlervermeidung automatisierter Montagesysteme im Produktionsanlauf. Dabei findet eine Unterteilung statt in die Ausgestaltung einer selbstlernenden fehlervorhersagenden und einer selbstlernenden fehlervermeidenden Systemkomponente. Das Kapitel endet anschließend mit der Diskussion möglicher Ansätze zur Dimensionsreduktion der zu betrachtenden Systemeingangsdaten.

In Kapitel 6 folgt die Beschreibung des ausgewählten Beispielsprozesses und die daran durchgeführte prototypische Umsetzung des entwickelten Konzepts. Die anhand dieser prototypischen Umsetzung durchgeführten Versuchsergebnisse werden anschließend aufgezeigt und hinsichtlich ihrer Bedeutung diskutiert. Mit Hilfe der aus der prototypischen Umsetzung erhobenen empirischen Versuchsergebnisse wird eine Detailierung und Bestätigung des in Kapitel 5 entwickelten Konzeptentwurfs durchgeführt.

Die Validierung und Verifizierung erfolgt in Kapitel 7. Hier werden die erhobenen Versuchsdaten sowie die gewonnenen Ergebnisse hinsichtlich einer allgemeinen Validierung kritisch diskutiert.

Die Arbeit schließt mit Kapitel 8 in dem eine Zusammenfassung der erarbeiteten Thematik erfolgt und auf eine mögliche Erweiterbarkeit des erarbeiteten und entwickelten Konzepts eingegangen wird.

## 2 Vorbetrachtung relevanter Themengebiete

### 2.1 Zukünftige Automatisierung in den Teilsystemen der Fahrzeugproduktion

#### 2.1.1 Automatisierungspotentiale in den Teilsystemen der Fahrzeugproduktion

Die Automobilindustrie ist von fundamentaler Bedeutung für die Wertschöpfung und die Beschäftigung in Europa und insbesondere in Deutschland (vgl. Schade et al. 2014, S. 38). Im Jahr 2016 wurden nach Angaben des Weltverbandes der Automobilverbände (vgl. OICA 2016) ungefähr 6 Millionen Kraft- und Nutzfahrzeuge in Deutschland gefertigt. Damit ist Deutschland im Jahr 2016 das Land mit der viertgrößten Fahrzeugproduktion weltweit. Die Fahrzeugproduktion unterteilt sich (vgl. Abbildung 3) dabei typischerweise in die vier großen Produktionsabschnitte Presswerk, Rohbau, Lackiererei und Endmontage (vgl. Michalos et al. 2010, S. 82; Claussen 2012, 219ff.).

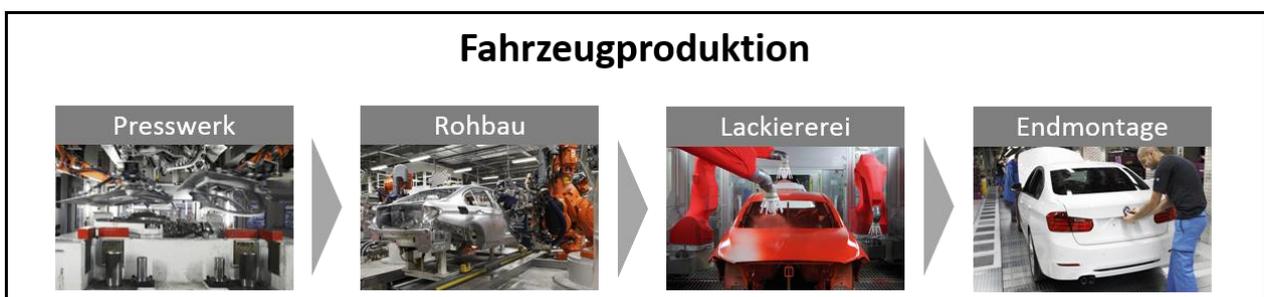


Abbildung 3: Teilsysteme der Fahrzeugproduktion. Eigene Darstellung in Anlehnung an (Claussen 2012; Michalos et al. 2010).

Im Presswerk beginnt die Fahrzeugproduktion mit dem Herausschneiden und Umformen von Einzelteilen aus einem Grundmaterial. Im nächsten Wertschöpfungsschritt werden diese Ein-

zelteile im Rohbau zu Grundkarossen gefügt, welche wiederum in der Lackiererei eine Oberflächenbehandlung erhalten. Diese Bereiche der Fahrzeugproduktion sind heute bereits stark automatisiert, sodass Personalkosten fast ausschließlich über Instandhaltungs- und Logistikkumfänge entstehen (vgl. Roscher 2008, S. 18).

Im letzten Abschnitt, der Fahrzeugendmontage, entsteht über den Einbau verschiedener vorgefertigter Module und Einzelteile schlussendlich das fertige Gesamtfahrzeug. Hier existiert im Gegensatz zu den vorgelagerten Wertschöpfungsstufen ein deutlich geringerer Anteil an Automatisierung von nur 5 % bis 10 % und damit verbunden auch ein höheres Potential zur Rationalisierung über Automatisierungstechnik. (vgl. Reinhart 1998, S. 2; Werner 2009, S. 1–2; Keller 2017, S. 4)

Dies gilt in besonderem Maße für Industriezweige mit Produktionsstandorten in Ländern mit hohen Lohnkosten.

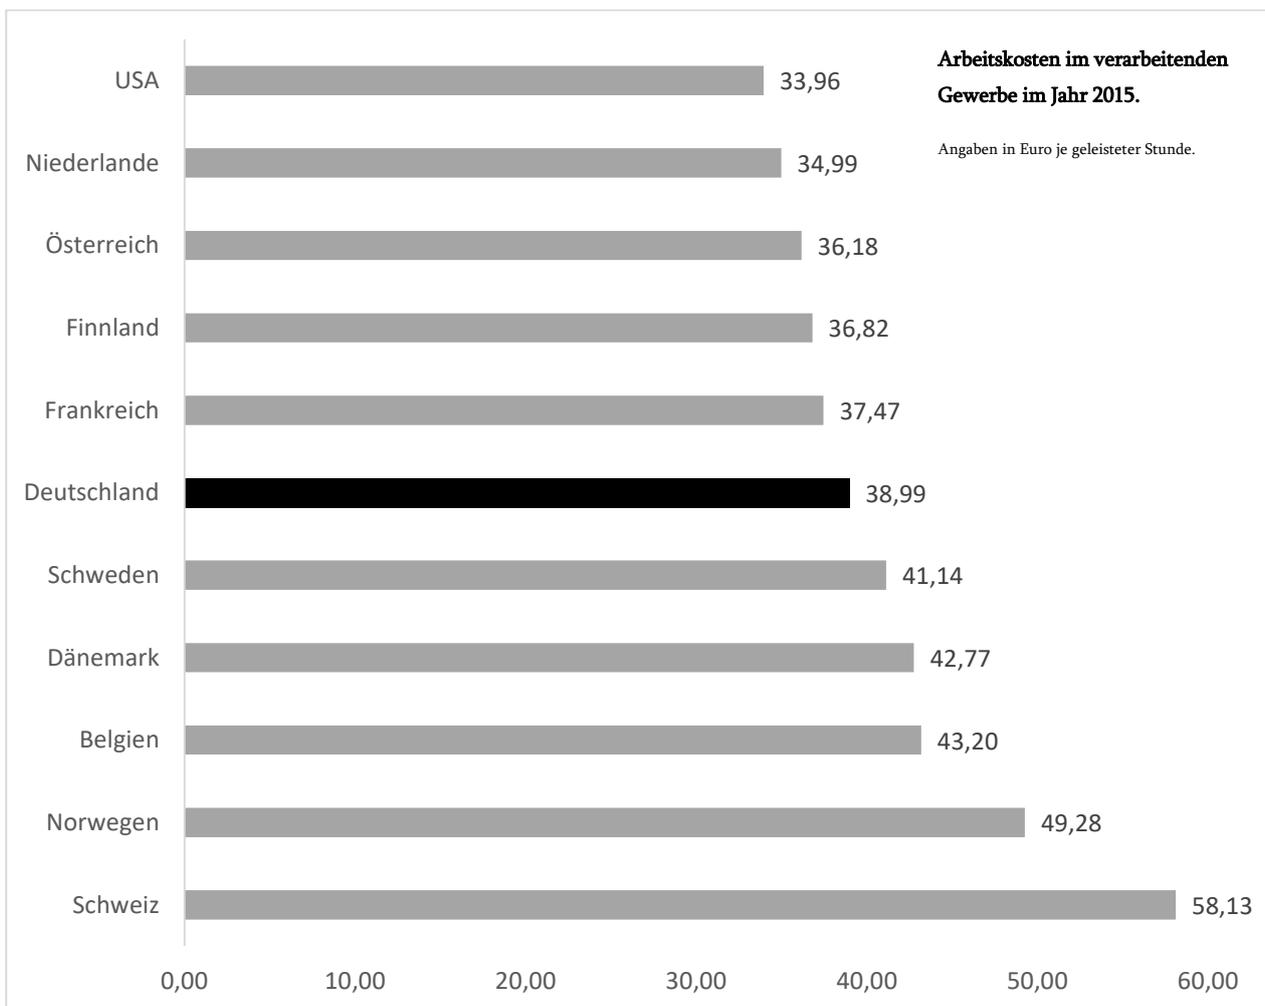


Abbildung 4: Industrielle Arbeitskosten des verarbeitenden Gewerbes 2015 im internationalen Vergleich nach (Schröder 2016).

Abbildung 4 zeigt einen internationalen Vergleich der Lohnkosten. Deutschland liegt dabei an sechster Stelle der Länder mit den höchsten Lohnkosten (vgl. Schröder 2016, S. 4). Das kosten-  
seitige Einsparungspotential durch eine Steigerung des Automatisierungsgrades ist am Standort  
Deutschland für die Automobilindustrie somit hoch.

Zudem beträgt der Anteil der Endmontage der Automobilindustrie nach Lotter und Wiendahl  
(2012) zwischen 30 % - 50 % der Gesamtfertigungszeit. Die grundlegenden Wirkpotentiale von  
Rationalisierungsmaßnahmen über Automatisierungstechnik sind in der Automobilendmon-  
tage somit als erheblich anzusehen.

Neben diesen aufgezeigten Potentialen wird die Automobilproduktion am Produktionsstand-  
ort Deutschland mit dem sogenannten demographischen Wandel konfrontiert. Unter diesem  
Begriff wird eine in den westlichen Gesellschaften existierende Veränderung der Altersstruk-  
tur eines Landes von einer Pyramidenform hin zu einer Urnenform verstanden, somit also die  
zunehmende Alterung einer Gesellschaft (vgl. Thim und Weber 2012, S. 361). Diese prozentu-  
ale Verschiebung der Altersgruppen hin zu älteren Jahrgängen führt zu einer kontinuierlichen  
Abnahme der erwerbsfähigen Bevölkerungsgruppe und auf lange Sicht somit zu einem Mangel  
an Arbeitskräften. Eine zunehmende Automatisierung gilt hier als eine mögliche Antwort auf  
die Herausforderungen durch den demographisch bedingten Fachkräftemangel (vgl. Schenk  
und Elkmann 2012, S. 110).

Eine zunehmende Automatisierung in Bereichen mit heute noch geringer Ausprägung an Au-  
tomatisierung, wie in der Automobilendmontage, scheint somit eine mögliche Folge des de-  
mographischen Wandels und eines steigenden Lohnkostendrucks in Europa und Deutschland.

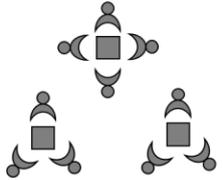
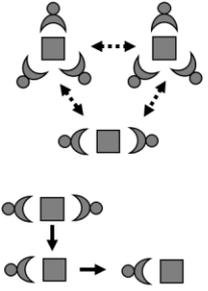
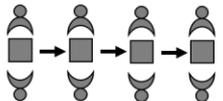
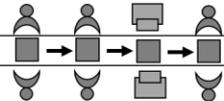
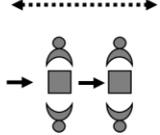
### 2.1.2 Endmontage in der Automobilfließfertigung

Die VDI-Richtlinie 2860 (vgl. VDI 1990) definiert Montieren als die Gesamtheit aller Vor-  
gänge, welche dem Zusammenbau von geometrisch bestimmten Körpern dienen (vgl. Lotter  
und Wiendahl 2012, S. 2; VDI 1990). Die Kernaufgabe der Montage besteht somit im Zusam-  
mensetzen vorgefertigter Baugruppen und -teile zu einem fertigen Endprodukt. Die Einfluss-  
größe Ablaufart berücksichtigt dabei die unterschiedlichen Organisationsformen in diesem Be-  
reich (vgl. Schenk et al. 2014, S. 372). Schenk et al. (2014) unterteilt Montagen dabei in fünf  
wesentliche Organisationsformen gemäß ihrer Ablaufart (vgl. Abbildung 5).

1. Baustellenmontage
2. Gruppenmontage
3. Reihenmontage
4. Fließmontage und
5. kombinierte Fließmontage.

Differenziert wird hierbei anhand der Kriterien Bewegungsablauf der Montageobjekte, Arbeitsplätze bzw. Montageeinrichtungen sowie dem Grad der Arbeitsteilung (vgl. Schenk et al. 2014, S. 372).

Kann ein Produkt aufgrund seiner Komplexität und/oder des geforderten Produktionsvolumens je Zeiteinheit nicht mehr wirtschaftlich an einem Einzelmontageplatz montiert werden, so muss der Montageaufwand auf mehrere verkettete Arbeitsplätze mit einer definierten Zeitvorgabe je Station verteilt werden. Dies wird als Fließmontage bezeichnet (vgl. Warnecke 1984, S. 487–488; Lotter und Wiendahl 2012, S. 135). Allen Ausprägungen der Fließmontage gemeinsam ist dabei die Notwendigkeit eines möglichst gleichen zeitlichen Arbeitsinhaltes pro Arbeitsplatz (vgl. Lotter und Wiendahl 2012, S. 135). Fließmontagen eignen sich besonders für den Einzelstückfluss von besonders komplexen und variantenreichen Produkt- und Stückzahlstrukturen (vgl. Prasch 2010, S. 69) und sind daher besonders im Umfeld der Automobil- und Nutzfahrzeugmontage weit verbreitet (vgl. Boysen 2005, S. 1, 2007, S. 12).

Baustellenmontage	Gruppenmontage	Reihenmontage	Fließmontage	Kombinierte Fließmontage
<ul style="list-style-type: none"> <li>Zuordnung von stationären Montageobjekten zu stationären Arbeitsplätzen; komplexer Zusammenbau der Erzeugnisse durch das Montagepersonal an einem Arbeitsplatz im Herstellerwerk</li> </ul> 	<ul style="list-style-type: none"> <li>Zuordnung von bewegten Arbeitsplätzen (Montagegruppen) zu stationären Montageobjekten oder umgekehrt; Arbeitsteilung (Montageabschnitte)</li> </ul> 	<ul style="list-style-type: none"> <li>Zuordnen von bewegten Montageobjekten zu stationären Arbeitsplätzen; gerichteter aperiodischer Bewegungsablauf der Montageobjekte (kein Taktzwang); definierte Arbeitsteilung</li> </ul> 	<ul style="list-style-type: none"> <li>Zuordnen von bewegten Montageobjekten zu stationären Arbeitsplätzen bzw. Montageeinrichtungen; gerichteter periodischer Bewegungsablauf der Montageobjekte (Taktzwang); definierte Arbeitsteilung</li> </ul> 	<ul style="list-style-type: none"> <li>Zuordnen von bewegten Montageobjekten zu bewegten Arbeitsplätzen; gerichteter Bewegungsablauf der Montageobjekte; zwischen den Takten definierte Arbeitsteilung</li> </ul> 
Kriterien: - Bewegungsablauf der Montageobjekte, Arbeitsplätze bzw. Montageeinrichtungen & - Grad der Arbeitsteilung				

Legende:

- Montageobjekt 
- Arbeitsplatz 
- Montageeinrichtung 
- Objektbewegung 
- Arbeitsplatzbewegung 

Abbildung 5: Ablaufarten der Montage nach (Schenk et al. 2014).

Als weiteres Kennzeichen der Fließfertigung gilt die objektive Zusammenfassung der Fertigungsmittel in Fertigungsablauffolge und eine exakte Kapazitätsbestimmung. Im Unterschied zur Reihenfertigung werden bei der Fließfertigung die einzelnen Bearbeitungsstationen häufig

zu starren Anlagen verkettet. Diese starre Verkettung von Arbeitsvorgängen führt zu einer hohen Spezialisierung der Mitarbeiter und hat die Vorteile einer hohen Durchlaufgeschwindigkeit sowie totalen Transparenz. Demgegenüber stehen jedoch die Nachteile fehlender Flexibilität und hoher Störanfälligkeit. Beim Ausfall einer Station fällt in der Regel die gesamte Fertigungskette aus. (vgl. Schenk et al. 2014, S. 372–374)

Um dieses Problem zu vermeiden, besteht die Möglichkeit Puffer zwischen den einzelnen Stationen zu implementieren, welche einen Teil der unabhängigen Stationsstillstände kompensieren, indem dort Produkte aus der Vorgängerstation gepuffert oder montierte Produkte an die Nachfolgestation freigegeben werden. Bei einer entsprechend großen Pufferkapazität werden die Stationen vollständig voneinander entkoppelt, dies wird als lose Verkettung bezeichnet (vgl. Lotter und Wiendahl 2012, S. 198). Abbildung 6 zeigt neben den beiden erläuterten Formen noch eine weitere Form, die sogenannte elastische Verkettung. Bei dieser werden nur begrenzte Pufferkapazitäten vorgehalten und es entsteht somit ein Kompromiss zwischen den möglichen hohen Verkettungsverlusten der starren Verkettung und den hohen Kosten für Puffer bei einer losen Verkettung.

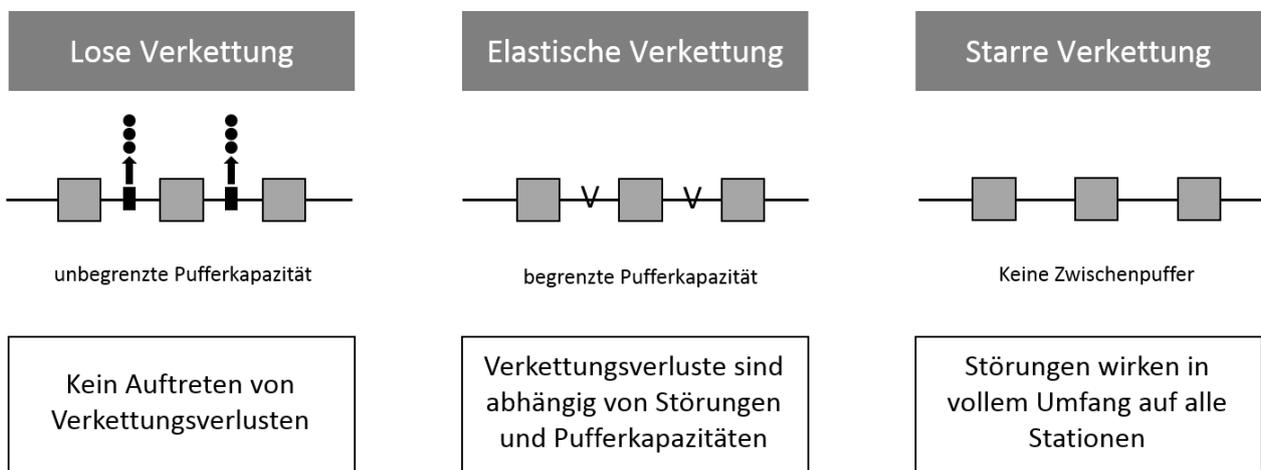


Abbildung 6: Verkettungsarten der mehrstufigen Fließfertigung. Darstellung nach (Lotter und Wiendahl 2012, S. 338).

In der Automobilendmontage findet heutzutage die Organisationform Fließmontage vorwiegend Anwendung. Die einzelnen Bearbeitungsstationen sind dabei häufig in einer kontinuierlich bewegten Fließmontage fast durchgängig starr verkettet und Puffer existieren lediglich vereinzelt zwischen einzelnen Bandabschnitten der Endmontage. (vgl. Motzer 2015, S. 13)

Stillstände einzelner Fertigungsketten in der Automobilendmontage haben damit nach kürzester Zeit unmittelbare negative Auswirkungen auf die Gesamtausbringungsmenge eines Fahrzeugwerks.

Eine der großen Herausforderungen an die Einführung von Automatisierungstechnik im Umfeld der Automobilendmontage liegt somit in einer hohen Anforderung an die Stabilität und Störungsrobustheit der eingesetzten Anlagen.

### 2.1.3 Herausforderungen bei der Umsetzung innovativer Automatisierung in der Automobilendmontage aus Planungssicht

Der Begriff Planung beschreibt nach VDI 5200: 2011 die „gedankliche Vorwegnahme eines angestrebten Ergebnisses einschließlich der zur Erreichung als erforderlich erachteten Handlungsfolge“ (vgl. VDI 2011). Wird dieser auf das Umfeld der industriellen Fabrikproduktion übertragen, ergibt sich unter dem Begriff Fabrikplanung nach VDI 5200: 2009 „der systematische, zielorientierte, in aufeinander aufbauende Phasen strukturierte und unter Zuhilfenahme von Methoden und Werkzeugen durchgeführte Prozess zur Planung einer Fabrik von der ersten Idee bis zum Anlauf der Produktion“ (vgl. VDI 2009, S. 2). Produktions- und Fabrikplanung sind damit wesentlicher Bestandteil der Unternehmensplanung (vgl. Kohler 2008, S. 8) und beschäftigen sich mit der Gestaltung von Fabriken sowie mit der rationellen Verwirklichung von Investitionsvorhaben (vgl. Schmigalla 1995, S. 70). Die Montageplanung stellt dabei einen speziellen Teilbereich der Produktionsplanung dar und umfasst auch die Planung innovativer Automatisierung in Form von Roboterzellen.

Abbildung 7 zeigt das allgemeine Planungsmodell nach VDI 5200: 2011. Nach der abgeschlossenen Detailplanung einer Anlage folgt demnach die Realisierung und damit ein An- und Hochlauf der Technologie. Eine erfolgreiche Planung ist dadurch gekennzeichnet, dass die Montage im Anschluss wirtschaftlich, mengengerecht, termingerecht, qualitätsorientiert, zielpreis- und variantengerecht erfolgt (vgl. Westkämper 2013, S. 3). Um diese Ziele zu erreichen, werden in der betrieblichen Praxis der Automobilindustrie Planungsabteilungen für die Montageplanung einer Produktionslinie beschäftigt. In einer durchgeführten Expertenbefragung bei einem namhaften deutschen Automobilhersteller wurden insgesamt neun Experten aus dem Umfeld der Automatisierungstechnik für Planung der Montage befragt. Zielsetzung der Befragung war dabei unter anderem die Identifikation des kritischen Teilprozesses beim Transfer einer neuartigen roboterbasierten Anlagentechnik in die Automobilendmontage aus Sicht der betrieblichen Praxis.

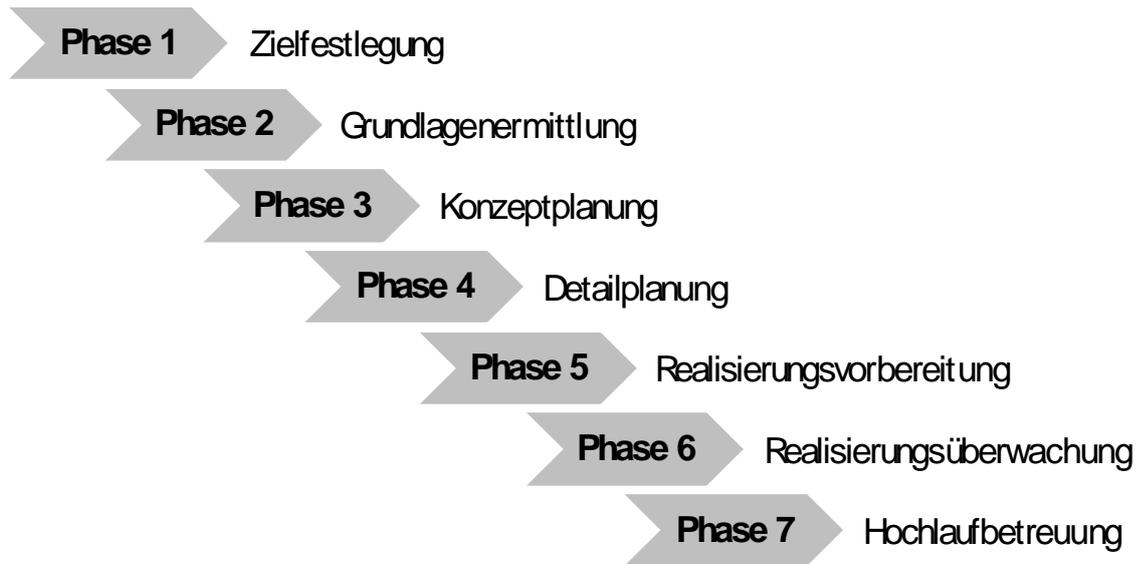


Abbildung 7: Planungsmodell gemäß VDI 5200 (VDI 2011).

Hierbei erfolgte die Unterteilung der Prozessschritte anhand der existierenden Transferlogik des Automobilherstellers in „Ideenphase“, „Proof of Concept“, „Konzeptionierung und Aufbau einer Serienversuchsanlage“ sowie „Überführung in den stabilen Serienbetrieb“. Die dabei in der betrieblichen Praxis verwendete Unterteilung des Innovationsprozesses für roboterbasierte Anlagentechnik ähnelt dem in der deutschen Literatur häufig zitierten Prozessschema in drei Hauptphasen nach Thom (vgl. Verworn und Herstatt 2000, S. 7) und kann diesem entsprechend zugeordnet werden.

Abbildung 8 zeigt ein Teilergebnis der durchgeführten Expertenbefragung. Dabei galten als Experten jene Mitarbeiter, deren täglicher Aufgabenbereich sich mit der Automatisierung in der Fahrzeugendmontage bei einem ausgewählten namhaften Automobilhersteller befasst und welche über mindestens 12 Monate Erfahrungen in diesem Bereich verfügten. Die Befüllung des Fragebogens erfolgte individuell online im Rahmen eines gemeinsamen Interviews zwischen Experte und Autor des Fragebogens. Über eine entsprechende Vorauswahl und die Etablierung einer Prüffrage wurde zudem sichergestellt, dass die befragten Personen die getroffenen Anforderungen an einen Experten erfüllen. Die Befragung zeigt, dass in der betrieblichen

Praxis aus Sicht der befragten Experten die größten Herausforderungen in der Phase der Überführung in den stabilen Serienbetrieb bzw. in der Realisierungsphase nach Thom liegen

*Fragestellung: „(...) Sie erhalten den Auftrag eine innovative Idee in eine funktionsfähige Serienprozessanlage zu überführen. In welcher der nachfolgenden Phasen existieren in der Realität Ihrer Meinung nach die größten Herausforderungen bei der Umsetzung?“*

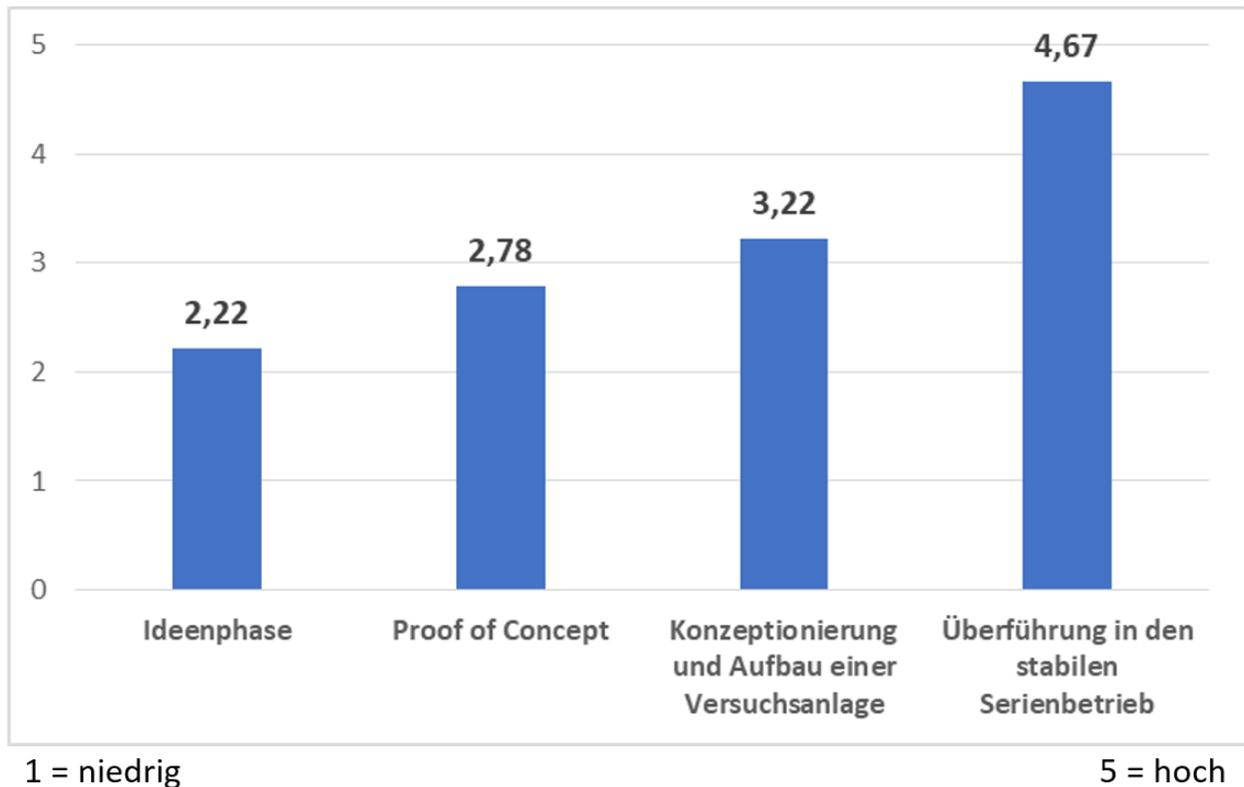


Abbildung 8: Ergebnisse Frage 2 Expertenbefragung Automobilendmontage des Beispielunternehmens.

Die Ergebnisse der weiterführenden Befragung derselben Experten liefern überdies auch eine mögliche Erklärung für die Tatsache, dass die Überführung in einen stabilen Serienbetrieb beim Transfer einer neuartigen roboterbasierten Anlagentechnik als kritischer Teilprozesses betrachtet wird. So wurde demnach eine konkrete neuartige Prozessanlage ohne sich verändernde externe Einflussparameter mit einer "hohen Prozesssicherheit" bewertet. Dieselbe Anlage unter schwankenden externen Einflussfaktoren wurde jedoch als "schwer umsetzbar" eingeschätzt. Demnach scheint in der Schwankung der externen Einflussfaktoren wie beispielsweise Temperatur, Schwingungen, Materialbeschaffenheit etc., eine besondere Herausforderung für die Anlaufstabilität zu liegen (vgl. Keller und Schönherr 2017, S. 4). Viele dieser externen Einflussfaktoren, wie beispielsweise Temperatur und Schwingungen, sind dabei an externe Umwelteinflüsse gebunden und eine Kontrollierung dieser ist somit nur sehr schwer

möglich. Weiterhin sind viele dieser Faktoren, je nach konkretem Aufstellungsstandort der Anlage, immer unterschiedlich und nur schwer vorhersagbar. Es ist beispielhaft nachvollziehbar, dass in Fabrikstandorten in mitteleuropäischen Ländern andere Jahrestemperaturen auftreten als an gleichartigen Produktionsstandorten in Südamerika oder Südafrika. Aber auch innerhalb einer Fabrik existieren neben Strukturen im Erdgeschoss häufig auch Bühnenstrukturen im ersten Obergeschoß, in denen nachvollziehbarerweise andere Bodenschwingungen denkbar sind als in den Betonstrukturen des Erdgeschosses derselben Fabrik.

#### 2.1.4 Aktuelle Trends und Entwicklungen der Automobilproduktion

Kaum ein Begriff dominiert die aktuelle Diskussion über die Perspektiven der Fertigungsindustrie so sehr wie Industrie 4.0 (vgl. Kroemer und Kasparick 2014, S. 76). Der Begriff entwickelt sich dabei immer mehr zu einem Buzz-Word in der IT-Branche und bei Anwendern – an einer einheitlichen Definition mangelt es bis heute (vgl. Huber 2016, 7ff.). Auf eine allumfassende Definition wird aus diesem Grund auch im Rahmen der vorliegenden Arbeit verzichtet und Industrie 4.0 nach Stocker et al. (2014) vielmehr als übergeordneter Begriff verstanden, welcher unterschiedlichste Trends für die Weiterentwicklung von Produktionsstätten zusammenfasst (vgl. Stocker et al. 2014, S. 207). Nach Huber (2016) werden unter dem Begriff Industrie 4.0 im Speziellen für die Automobilproduktion insgesamt zwölf bedeutende technologische Trends vorgestellt. Bei den vorgestellten Technologien handelt es sich überdies vielfach nicht um völlig neue Ansätze, sondern auch häufig um die Weiterentwicklung bereits länger bestehender technologischer Konzepte (vgl. Huber 2016, S. 33). Abbildung 9 veranschaulicht diese zwölf Technologien. Hieraus werden im Folgenden die Technologien Sensitive Roboter und cyber-physische Systeme aufgrund ihrer besonders unmittelbaren thematischen Relevanz für die Weiterentwicklung von roboterbasierten Automatisierungslösungen für die Automobilendmontage detaillierter betrachtet.

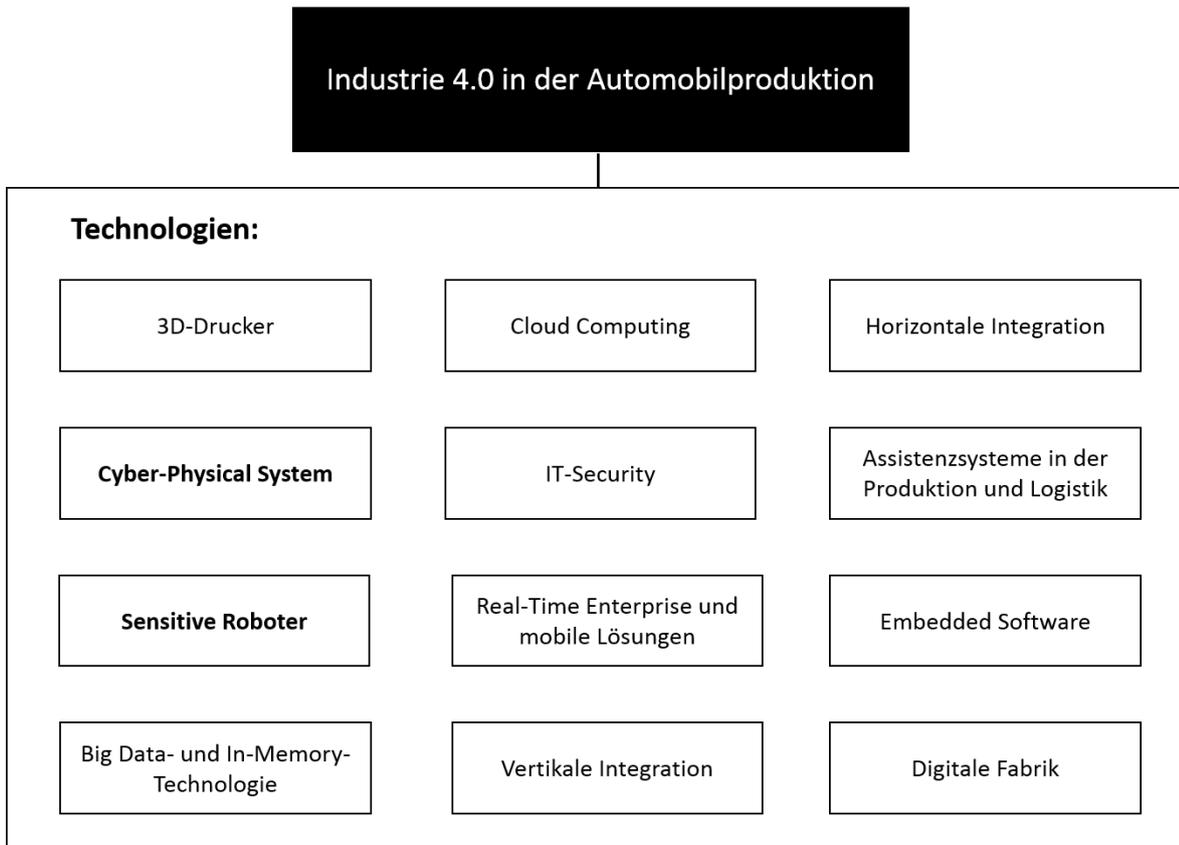


Abbildung 9: Technologien Industrie 4.0 in der Automobilproduktion. Eigene Darstellung nach (Huber 2016).

### **Sensitive Roboter**

Roboter gelten als Inbegriff der Automatisierung. Aber auch hier ergeben sich durch neuartige Ansätze weitergehende Einsatzgebiete, welche die Produktionswelt nachhaltig verändern werden. (vgl. Huber 2016, S. 50)

Nach Spath et al. (2013) wird auch in Zukunft die menschliche Arbeit der Schlüsselfaktor für die Produktivität am Produktionsstandort Deutschland bleiben (vgl. Spath et al. 2013, S. 46). In Wissenschaft und Praxis werden hierfür derzeit unterschiedliche Konzepte zur fähigkeitsorientierten und unmittelbaren Zusammenarbeit von Mensch und Maschine im Montageumfeld entwickelt (vgl. Krüger et al. 2009, S. 628–635). Einer dieser neuartigen Ansätze ist die Entwicklung sensitiver Roboter, die durch ihre sicherheitstechnische und konstruktive Harmlosigkeit dem Werker im Kontaktfall keine Verletzungen zufügen und somit unter gewissen Voraussetzungen für den Einsatz in gemischter Umgebung mit dem Menschen geeignet sind (vgl. Matthias et al. 2013, S. 1). Um ein direktes Miteinander von Robotern mit Menschen zu ermöglichen, reagieren diese Systeme mittels Kraftsensoren auf geringste äußere Kräfte und realisieren dadurch einen Kollisionsschutz. Tritt ein unerwarteter Kontakt auf, so wird die Bewegungsgeschwindigkeit sofort auf ein Minimum reduziert (vgl. Huber 2016, S. 51). Sensitive

Roboter werden dabei vielfach in Leichtbauweise hergestellt, sodass daher auch häufig von sensitiven Leichtbaurobotern gesprochen wird (vgl. Bauernhansl et al. 2014). Sensitive Leichtbauroboter haben die Fähigkeit sehr feinfühlig auf ihre Umwelt zu reagieren. Damit können sie in voller Arbeitssicherheit ohne Schutzzäune mit Menschen an einer Station zusammenarbeiten und darüber hinaus nahezu jede Montagetätigkeit ausführen (vgl. Steegmüller und Zürn 2014, S. 110). Markus Schäfer, Bereichsvorstand des Mercedes-Benz Cars Produktion & Supply Chain Managements, äußerte sich in einem Interview im April 2015 wie folgt:

„Sie glauben nicht, wie schwierig dieser letzte Schritt ist. Zum Beispiel ist es ein scheinbar einfacher Vorgang, einen Stopfen in ein Loch in einem Blech zu drücken. Allerdings kann sowohl die Größe des Stopfens als auch die des Lochs variieren. Das Einrasten des Stopfens kann ein Mensch hören und fühlen, der Roboter nicht.“ (vgl. Gerster 2015, S. 1).

Durch den Einsatz sensibler Roboter vollzieht sich hier ein Paradigmenwechsel und Prozesse wie das kraftsensitive Fügen biegeschlaffer Bauteile wie Gummistopfen werden damit auch für diese neue und sensitive Generation an Robotern möglich. Überdies können sensitive Leichtbauroboter mit ihren neuen Fähigkeiten Montagevorgänge in nur teilweise bekannten Umgebungen präzise und zuverlässig ausführen und damit also auch für Aufgaben eingesetzt werden, die über herkömmliche Industrieroboter bisher nur mit großem Aufwand für Positionierhilfen und Sensorik am Werkzeug lösbar waren. (vgl. Steegmüller und Zürn 2014, S. 111).

Sensitive Roboter ermöglichen folglich eine einfache Automatisierung vieler Montageaufgaben, welche bis dahin häufig nicht wirtschaftlich oder technisch umsetzbar waren. Aufgrund ihrer neuen Fähigkeiten werden sensitive Roboter zukünftig einen wichtigen Bestandteil in der Endmontage darstellen und damit zu einem gravierenden Anstieg der Automatisierungsrate führen (vgl. Huber 2016, S. 268).

### **Cyber-physische Systeme**

Der Begriff cyber-physischer Systeme (abgekürzt CPS) ist als Schlagwort „cyber-physical systems“ aus den USA bekannt geworden und ist in kürzester Zeit zum allgegenwärtigen Begriff in der aktuellen Diskussion über zukünftige technische und industrielle Trends und Herausforderungen geworden. An einer einheitlichen, allgemein anerkannten Definition mangelt es auch hier. Dennoch zeigt sich in der Literatur eine zunehmende Entwicklung hin zu einem einheitlichen Verständnis der Eigenschaften und Charakteristika von CPS (vgl. Bettenhausen und Kowalewski 2013, S. 2–3).

Nach Geisberger und Broy (2012) sind cyber-physische Systeme gemäß der Forschungsagenda CPS über fünf aufeinander aufbauende Dimensionen charakterisiert, die eine Evolution hin zu einer zunehmenden Offenheit, Komplexität und Intelligenz bedeuten. Diese Dimensionen lauten dabei wie folgt (wörtlich zitiert aus Geisberger und Broy 2012):

- (1) Verschmelzung von physikalischer und virtueller Welt
- (2) System of Systems mit dynamisch wechselnden Systemgrenzen
- (3) kontextadaptive und ganz oder teilweise autonom handelnde Systeme; aktive Steuerung in Echtzeit
- (4) kooperative Systeme mit verteilter, wechselnder Kontrolle
- (5) umfassende Mensch-System-Kooperation

Die Verknüpfung und Verschmelzung von physischen Objekten und Prozessen eines Automatisierungssystems mit informationsverarbeitenden Einheiten ist seit vielen Jahrzehnten in Automatisierungssystemen bereits Stand der Technik (vgl. Färber 1980, S. 207). Zudem ist ebenfalls die ständige Vernetzung der Automatisierungskomponenten untereinander heute selbstverständlich (vgl. Bettenhausen und Kowalewski 2013, S. 2). Das erste wirklich neue Charakteristikum von CPS nach Geisberger und Broy (2012) ist somit ihre Fähigkeit, sich an die entsprechenden Umgebungssituationen und Anforderungserfordernisse im Sinne einer Kontextadaptivität anzupassen und damit teilautonom oder vollständig autonom zu handeln. Übertragen auf Automatisierungssysteme liegt an dieser Stelle folglich der derzeitige Entwicklungsbedarf. Es werden Konzepte benötigt, die den Systemen eine Adaptivität und Autonomie ermöglichen, bevor die nächsten darauf aufbauenden Dimensionen von CPS realisiert werden können. Dem Merkmal eigenständiger Anpassungsfähigkeit kommt dabei eine besondere Bedeutung zu, da es nicht nur Kommunikation und Koordination umfasst, sondern diesbezüglich vielmehr auch die gesamten Bereiche von Aktorik und physikalischen Prozessen ebenso wie Informations- und Managementprozessen betrachtet werden (vgl. Geisberger und Broy 2012, S. 62). Es werden dadurch adaptive, sich selbst steuernde und sich selbst konfigurierende beziehungsweise optimierende Produktionsanlagen möglich. Hierfür bedarf es cyber-physischer Produktionssysteme, kurz CPPS, und damit einer Nachfolgegeneration heutiger MES (engl. Manufacturing Execution Systems) (vgl. Huber 2016, S. 39). Der Begriff CPPS stellt somit eine Eingrenzung cyber-physischer-Systeme auf das gesamte Produktionsumfeld dar. Umfasst werden dabei alle Aspekte von Produktionsprozessen über Maschinen bis hin zu Produktions- und

Logistiknetzwerken (vgl. Monostori 2014, S. 10). Es ergibt sich für CPPS wie beschrieben die Notwendigkeit, autonom auf Änderungen in ihrer Umgebung reagieren zu können (vgl. Kowalewski et al. 2014, S. 4). Dies bedeutet, dass sich das System auch an unvorhergesehene und neue Situationen und Ereignisse anpassen kann (vgl. Geisberger und Broy 2012, S. 63). CPPS benötigen hierfür die Fähigkeit, die ideale Performance eines Systems zu kennen und Abweichungen der realen Systemperformance von der idealen wahrzunehmen sowie über entsprechende Maßnahmen eine Verbesserung des Systemverhaltens zu bewirken (vgl. Sterritt 2005, S. 80). Voraussetzung dafür ist, dass CPPS neben der Fähigkeit der umfassenden Wahrnehmung und des entsprechenden Handelns auch in der Lage sind, die richtige Entscheidung zu treffen. Derartige cyber-physische-Systeme benötigen jedoch geeignete Konzepte, welche es diesen Systemen ermöglichen eigenständig zu lernen und Anpassungen ihres Verhaltens auf unbekannte Situationen einzuleiten (vgl. Ennen et al. 2016, S. 57).

## 2.2 Produktionsanlaufsteuerung

### 2.2.1 Allgemeines und Grundlagen

In den letzten zehn bis fünfzehn Jahren hat sich die wissenschaftliche Literatur an verschiedenen Stellen und aus unterschiedlichen Perspektiven heraus intensiv mit dem Produktionsanlauf auseinandergesetzt. Über nahezu alle Quellen hinweg findet sich dabei eine einheitliche Definition der Produktionsanlaufphase, die auf die erste gegebene Definition nach Bohn und Terwiesch (1999) zurückgeht (vgl. Surbier et al. 2014, S. 1266). Der Produktionsanlauf ist dabei definiert als die Periode zwischen dem Abschluss der Entwicklung und dem Erreichen der vollen Kapazitätsauslastung eines Produktionssystems (vgl. Bohn und Terwiesch 1999, S. 47). In Anlehnung an diese Definition soll der hier verwendete Begriff Produktionsanlauf nach Wiendahl et al. (2002) im Folgenden als Synonym für den Anlauf eines Produktionssystems zur Produktion von Serienprodukten gelten (vgl. Wiendahl et al. 2002, S. 650–651).

Der Produktionsanlauf dient der Aufnahme von Neuerungen in die industrielle Produktion (vgl. Renner und Dyckhoff 2012, S. 6) und ist dabei häufig mit Herausforderungen in der Zielerreichung verbunden. Abbildung 10 zeigt die Ergebnisse einer Studie in der europäischen Automobilzuliefererindustrie zur Erfolgsrate von Produktionsanläufen nach Straube und Fitzek (2005).

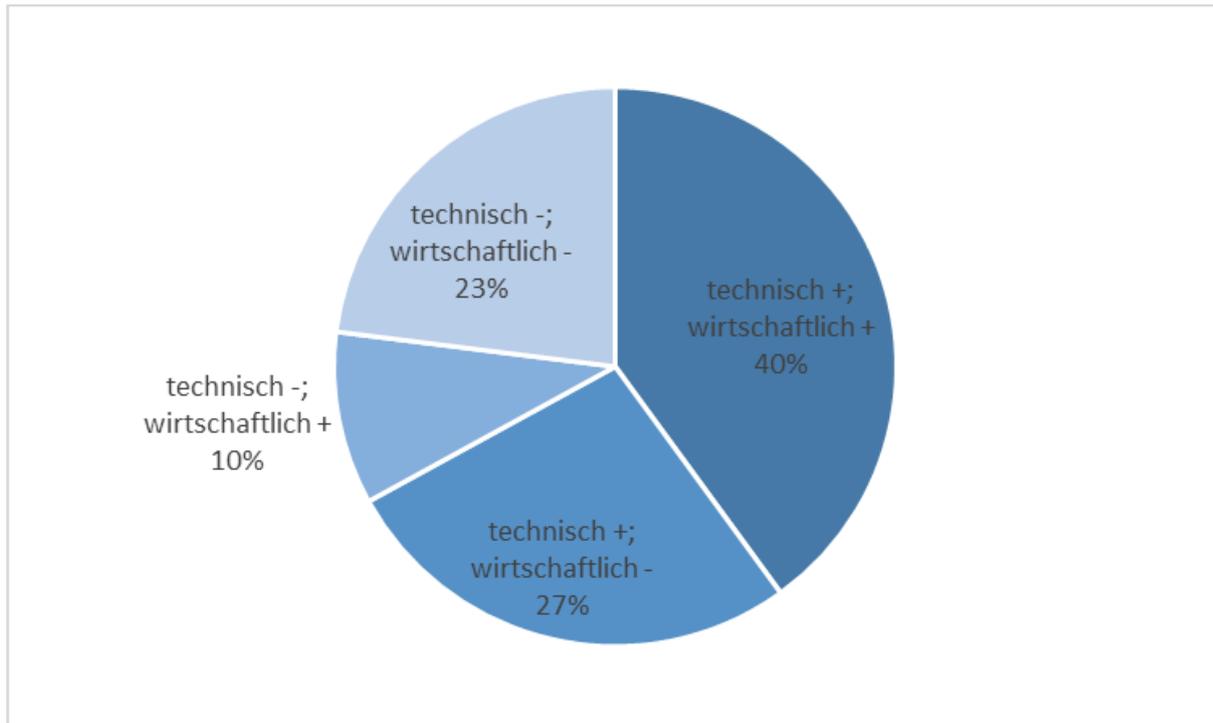


Abbildung 10: Erfolgsrate von Produktionsanläufen in der europäischen Automobilzulieferindustrie nach (Straube und Fitzek 2005).

Dabei waren lediglich 40 % der bewerteten Anläufe technisch wie auch wirtschaftlich erfolgreich. 27 % erreichten die technischen aber nicht die wirtschaftlichen Ziele, 10 % erreichten zwar die wirtschaftlichen Zielsetzungen aber scheiterten hinsichtlich der technischen Ziele und ganze 23 % der bewerteten Anläufe konnten sowohl die technischen als auch die wirtschaftlichen Ziele nicht erreichen (vgl. Straube und Fitzek 2005, S. 44–47).

Eine von Meier und Hormuth (2006) erwähnte Studie in derselben Industrie kommt auf beinahe identische Ergebnisse. So wurden hier nur 43 % der Anläufe als technisch und wirtschaftlich erfolgreich bewertet. 24 % erreichten weder die technischen noch die wirtschaftlichen Ziele, weitere 24 % erreichten zwar die wirtschaftlichen aber nicht die technischen Ziele und 9 % waren technisch erfolgreich aber verursachten zu hohen Kosten (vgl. Meier und Hormuth 2006). In beiden Studien erreichten also weniger als die Hälfte der bewerteten Produktionsanläufe in der Automobilindustrie ihre Zielsetzungen. Eine der möglichen Ursachen dafür liegt darin, dass Produktionssysteme im Anlauf sowohl externen als auch internen Störeinflüssen ausgesetzt sind, welche sich nur schwer oder gar nicht kontrollieren lassen (vgl. Wiendahl et al. 2002, S. 653).

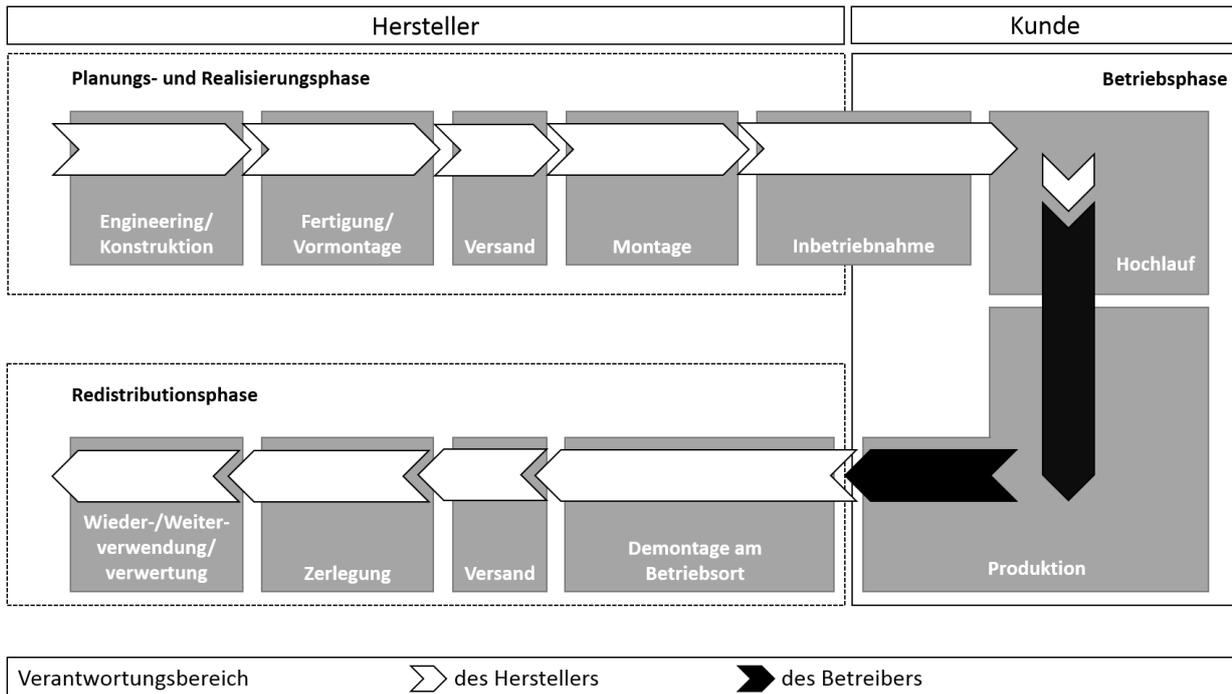


Abbildung 11: Betriebsphase im Lebenszyklus von Produktionssystemen nach (Wiendahl et al. 2002).

Abbildung 11 zeigt die Betriebsphase im Lebenszyklus von Produktionssystemen. Gemäß der Motivation und Zielsetzung dieser Arbeit wurde der Begriff Produktionsanlauf nach Wiendahl et al. (2002) als Synonym für den Anlauf eines gesamten Produktionssystems zur Produktion von Serienprodukten definiert. Übertragen auf den Anlagenlebenszyklus ergibt sich damit, dass der Produktionsanlauf der Inbetriebnahme plus Hochlauf entspricht (vgl. Wiendahl et al. 2002, S. 650).

Der Begriff Anlaufmanagement umfasst die Koordination zielführender Aktivitäten hinsichtlich des Produktionsanlaufs. Ein Ziel des Anlaufmanagements ist die Entzerrung und Beherrschung der technischen Störungen in der Anlaufphase. (vgl. Schmitt 2015, S. 3)

Das Anlaufmanagement ist dabei ein maßgeblicher Erfolgsfaktor für ein Unternehmen, da es zur Beherrschung von Time-to-Market, Time-to-Volume sowie von Kosten, Qualität und Komplexität beiträgt (vgl. Straube 2004, S. 256).

Das Anlaufmanagement unterteilt sich (vgl. Abbildung 12) in die Anlaufstrategie, Anlaufplanung, Anlauforganisation und Anlaufsteuerung (vgl. Schmitt 2015, S. 2).



Abbildung 12: Facetten des Anlaufmanagement. Eigene Darstellung in Anlehnung an (Schmitt 2015).

### **Anlaufstrategie**

Die Anlaufstrategie definiert den generellen Standpunkt eines Unternehmens für sämtliche Anläufe und koordiniert alle Aktivitäten in der Umsetzung der einzelnen Anläufe (vgl. Schuh et al. 2008, S. 4). Weiterhin operationalisiert eine Anlaufstrategie die Ziele der Unternehmensstrategie für den Anlauf und gibt somit ein übergeordnetes Regelwerk für sämtliche Anläufe an allen Standorten (vgl. Peters und Hofstetter 2008, S. 12).

### **Anlaufplanung**

Zielsetzung und Aufgabe der Anlaufplanung ist die Konzeptentwicklung für die technologische Gestaltung des Produktionssystems und die Ausarbeitung eines organisatorischen Ablaufschemas für die Umsetzung dieses Konzepts (vgl. Risse 2003, S. 183). Hierfür werden häufig über die Festlegung von Meilensteininhalten im Rahmen einer Meilensteinplanung die erwarteten Ergebnisse zu unterschiedlichen Phasen definiert (vgl. Bürgel et al. 1996). Über einen Soll-Ist-Abgleich erfolgt dabei die Überwachung des Projektablaufs.

### **Anlauforganisation**

Die Anlauforganisation lässt sich in die zwei Teilbereiche der Anlauf-Aufbauorganisation und Anlauf-Ablauforganisation unterteilen. Ziel der Anlauf-Aufbauorganisation ist es alle beteiligten Bereiche formal und räumlich zu strukturieren, während die Anlauf-Ablauforganisation die Festlegung der zeitlichen und logischen Ablaufbeziehungen fokussiert (vgl. Franzkoch und Gottschalk 2008, S. 55). Die Aufbauorganisation nutzt dabei Organisationsformen wie die Projekt-Matrix-Organisation oder permanente Anlaufteams (vgl. Schmitt 2015, S. 4).

Die Aufbauorganisation schafft und etabliert damit klare Strukturen und vermeidet Kompetenzgerangel, mangelnde Kooperationsbereitschaft und Ressourcenkonflikte. (vgl. Franzkoch

und Gottschalk 2008, S. 60–61) „Während die Aufbauorganisation die strukturellen Rahmenbedingungen vorgibt, regelt die Ablauforganisation die innerhalb der Aufbauorganisation ablaufenden Arbeits- und Informationsprozesse“ (vgl. Franzkoch und Gottschalk 2008, S. 56).

### **Anlaufsteuerung**

Die Anlaufsteuerung findet in der Inbetriebnahme-Phase sowie im Hochlauf eines Produktionssystems statt und wirkt damit über den gesamten Zeitraum des Produktionsanlaufs (vgl. Abbildung 13). Allgemeines Ziel der Anlaufsteuerung ist es den Anlauf, unter Berücksichtigung aller seiner Randbedingungen, zu beherrschen und zu einer signifikanten Verkürzung der Anlaufphase beizutragen (vgl. Fleischer et al. 2004, S. 29–32).

Die Anlaufsteuerung leitet über entsprechende Maßnahmen die Beeinflussung und Erreichung der gewünschten Ausgangsgrößen eines Anlaufs (vgl. Schmitt 2015, S. 3). Mit anderen Worten besteht die Aufgabe der Anlaufsteuerung in der Zielerreichung des Produktionsanlaufs. Die Anlaufsteuerung von roboterbasierten Montageprozessanlagen ist dabei eine Teilmenge dieser Produktionsanlaufsteuerung. Es stellt sich weitergehend die Frage, welche generellen Ziele im Rahmen eines Produktionsanlaufs verfolgt werden, welche Faktoren diese Ziele gefährdend beeinflussen und über welche Größen und Kennzahlen diese Ziele messbar sind.

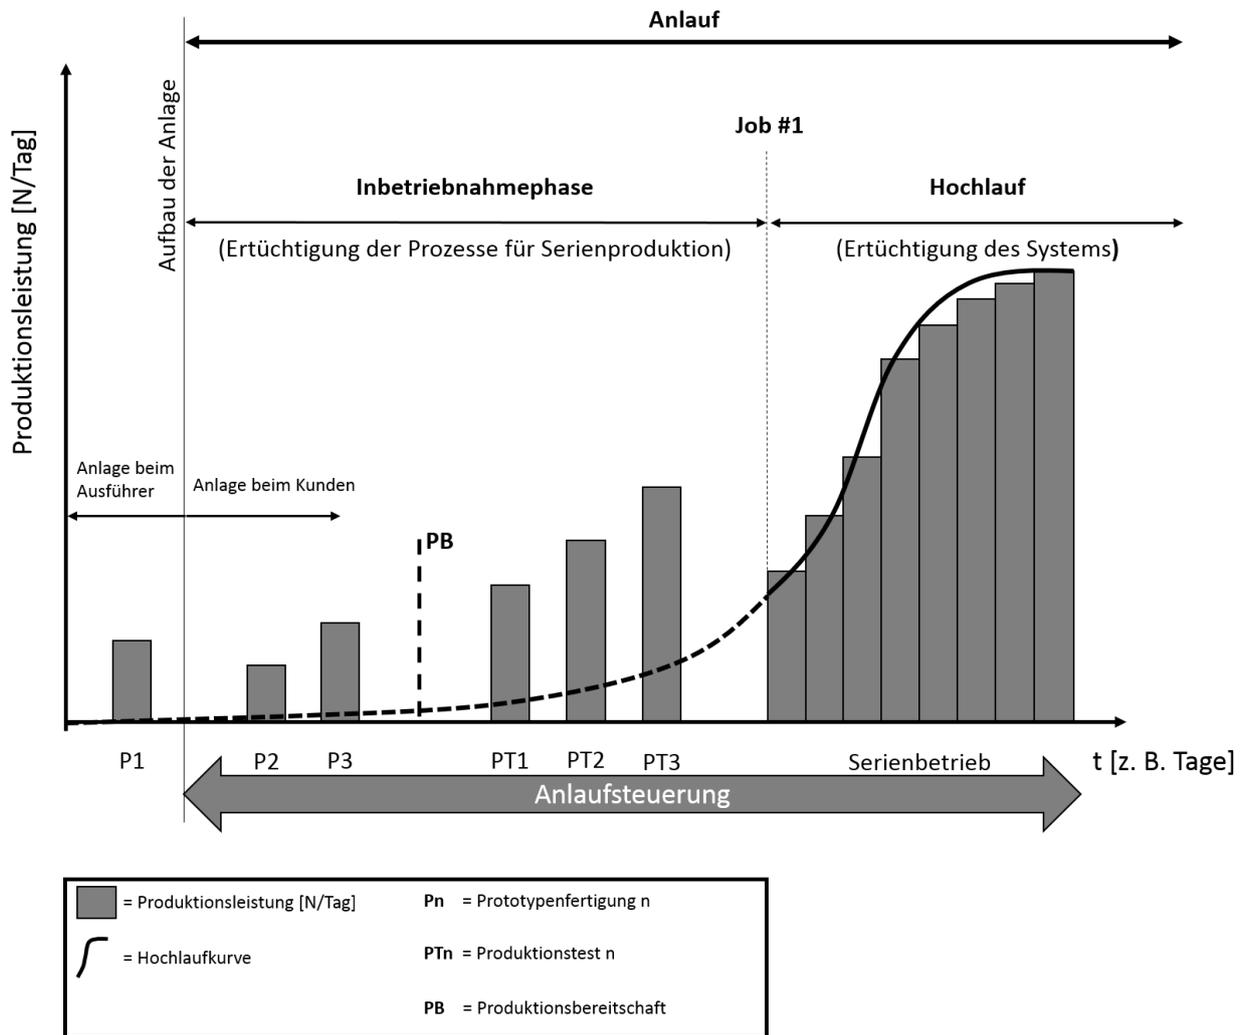


Abbildung 13: Einsatzzeitraum der Anlaufsteuerung. Verallgemeinerte Darstellung nach (Fleischer et al. 2007).

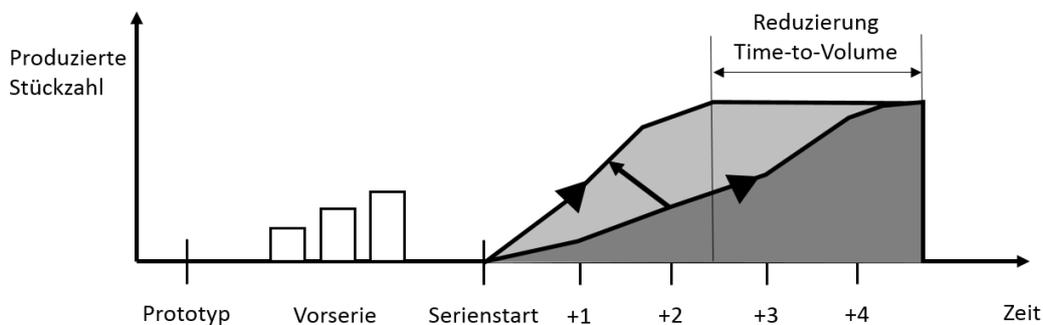
### 2.2.2 Zielgrößen des Produktionsanlaufs

Der Produktionsanlauf ist definiert (vgl. Kapitel 2.2.1) als Zeitabschnitt, der mit dem Ende der Entwicklung beginnt und mit dem Erreichen der stabilen Serienproduktion bei voller Kapazitätsauslastung endet. Der Produktionsanlauf verfolgt somit das Ziel, die Ausbringung der Produktion bis zum Erreichen der sog. „Kammlinie“ zu erhöhen (vgl. Terwiesch und E. Bohn 2001, S. 1; Peters und Hofstetter 2008, S. 10). Die Kammlinie beschreibt das Erreichen einer geplanten Produktionsmenge (vgl. Gronau 2008, S. 283) und ist zum einen durch eine hohe Auslastung der Betriebsmittel und zum anderen durch ein im Vorhinein entsprechend festgelegtes Qualitätsniveau definiert. Die grafische Darstellung des jeweiligen Produktionsvolumens über

die Anlaufperiode hinweg wird als Anlaufkurve bezeichnet (vgl. Peters und Hofstetter 2008, S. 10). Abbildung 13 zeigt den Verlauf einer idealtypischen Anlaufkurve.

Aufgrund der immer kürzer werdender Produktlebenszyklen sind die Kosten und die Dauer der Produktionsanlaufphase von zunehmender Bedeutung (vgl. Winkler et al. 2007, S. 103–104). Dies liegt vor allem an der sich damit verkürzenden Zeitspanne, die zur Amortisation der Investitions- und Entwicklungskosten zur Verfügung steht. Um die Deckungsbeitragsgenerierung und damit die wirtschaftliche Zielerreichung zu verbessern, kann entweder die Hochlaufkurve beschleunigt oder die Time-to-Market verkürzt werden (vgl. Bischoff 2007, S. 8). Eine Verkürzung der Time-to-Market ist dabei auch stark an die benötigte Entwicklungsdauer geknüpft (vgl. Abbildung 1, S. 2) und stellt somit eine Variable dar, die über eine exzellente Produktionsanlaufsteuerung nur indirekt beeinflusst werden kann. Aus einer Beschleunigung der Anlaufkurve (vgl. Abbildung 14) resultieren eine Verkürzung der Time-to-Volume und damit ein potentieller direkter positiver Beitrag des Anlaufmanagements zur Erreichung der wirtschaftlichen Ziele.

### 1. Beschleunigung der Anlaufkurve



### 2. Verkürzung der time-to-market

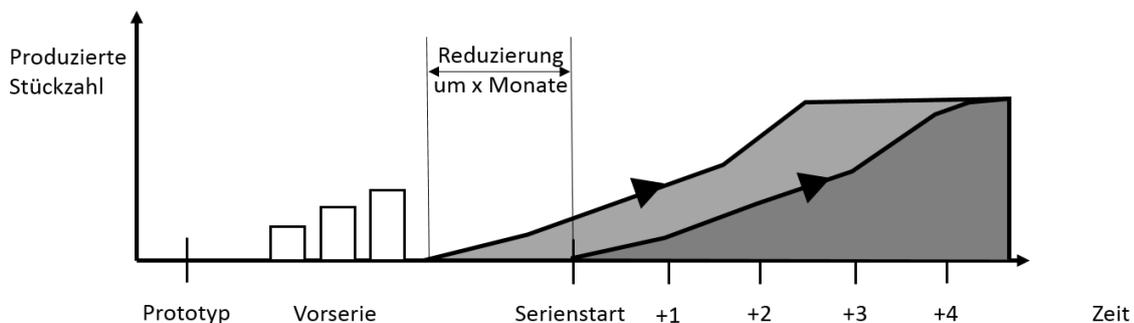


Abbildung 14: Beschleunigung der Anlaufkurve und Verkürzung der „Time-to-Market“. Darstellung aus (Bischoff 2007) in Anlehnung an (Wildemann 2006; Risse 2003) erweitert um die „Time-to-Volume“.

Eine beschleunigte Erreichung der Kammlinie ermöglicht einen frühzeitigeren Absatz hoher Stückzahlen und damit eine Verkürzung der Amortisationszeit. Zusätzlich werden Planungskosten, Investitionen in Betriebsmittel und Produktionsflächen über eine kürzere Zeit gebunden, wodurch sich die Rentabilität der produzierten Produkte erhöht (vgl. Wiendahl et al. 2002, S. 653). Abbildung 15 zeigt die detaillierten kostenseitigen Einsparpotentiale im Anlauf.

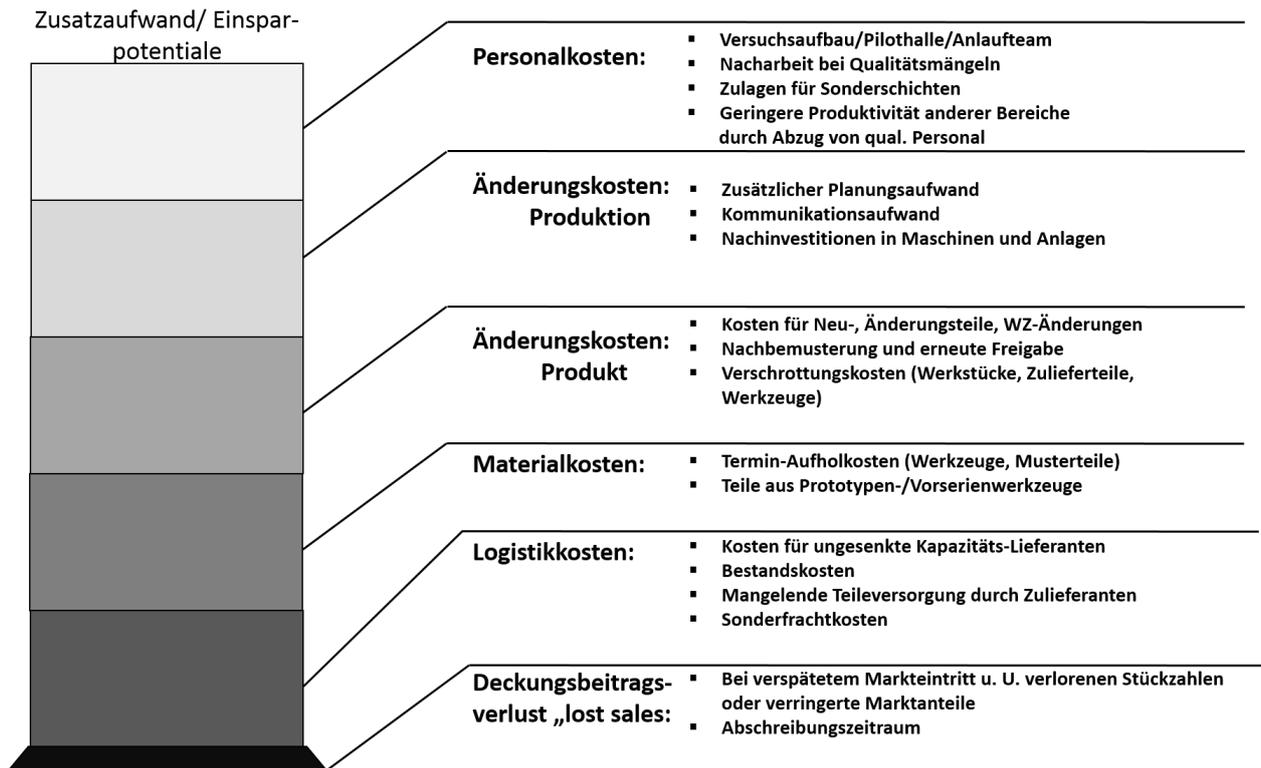


Abbildung 15: Kostenseitige Zusatzaufwendungen/Einsparpotentiale im Anlauf nach (Weber 2002) in (Wiendahl et al. 2002).

Wildemann (2015) spezifiziert für den Produktionsanlauf drei Hauptzielsetzungen – die Verkürzung der Anlaufzeit, Produktqualität und die Verringerung der Anlaufkosten – und fügt somit den beiden bereits genannten Dimensionen Kosten und Zeit noch die Dimension Qualität hinzu. Abbildung 16 zeigt das sogenannte „magische Dreieck“ aus Kosten, Qualität und Zeit, welches am häufigsten in der Performancebewertung eines Produktionsanlaufs herangezogen wird (vgl. Surbier et al. 2014, S. 1271). Diese drei Hauptziele werden in der Regel nicht unabhängig voneinander verfolgt, sondern es wird vielmehr ein Optimum zwischen diesen Zielgrößen angestrebt (vgl. Näser und Müller 2008, S. 263). Nach Fleischer et al. (2003) ist im Kontext der Automobilindustrie die Zielgröße der Qualität dabei von besonders großer Bedeutung, da

die Qualität im Anlauf einen direkten und indirekten Einfluss auf die anderen Zielgrößen ausübt. Zeit und Kosten im Anlauf können somit als Funktionen in Abhängigkeit der Qualität im Anlauf beschrieben werden (vgl. Fleischer et al. 2003, 150ff.).

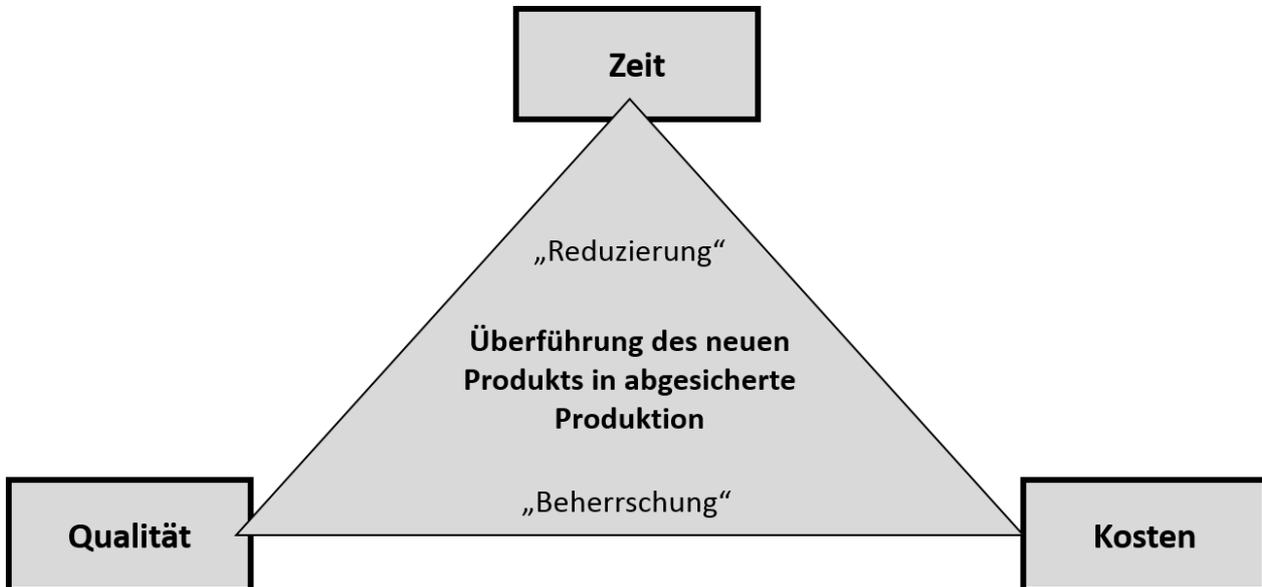


Abbildung 16: Zieldimensionen Produktionsanlauf. Darstellung aus (Peters und Hofstetter 2008) in Anlehnung an (Schneider und Lücke 2002).

Im Produktionsanlauf wirken jedoch oftmals Störeinflüsse, welche die Erreichung der Zielgrößen im Produktionsanlauf erschweren (vgl. Wiendahl et al. 2002, S. 653). Im folgenden Kapitel schließt sich eine Diskussion über den Störungsbegriff im Anlauf sowie möglicher Ursachen von Störungen an.

### 2.2.3 Störungen im Produktionsanlauf

Nagel (2011) definiert Störungen für den Produktionsanlauf als ungeplante Ereignisse, die eine negative Auswirkung auf die Prozesse im Anlauf oder auf die Erreichung der geplanten Anlaufziele haben (vgl. Nagel 2011, S. 40). Bockholt (2012) erweiterte diese Störungsdefinition um zusätzliche Dimensionen, die nach Ulrich (2016) auch auf den Produktionsanlauf anwendbar sind (vgl. Ulrich 2016, S. 35). Tabelle 1 gibt einen Überblick über diese neun Dimensionen einer Störung.

Störungen im Anlauf werden dabei durch Störeinflüsse ausgelöst, welche interner oder externer Art sein können. Interne Störeinflüsse stammen aus dem eigentlichen Systemanlauf selbst und lassen sich somit auf Ursachen innerhalb der Betrachtungseinheit zurückführen. Externe Störeinflüsse wirken von außen auf eine Betrachtungseinheit und stammen aus vorgelagerten

oder zeitlich parallel stattfindenden Prozessen. (vgl. Wiendahl et al. 2002, 653ff.; Bockholt 2012, S. 43)

Tabelle 1: Dimensionen des Störungsbegriffes. Darstellung nach (Ulrich 2016, S. 35) in Anlehnung an (Bockholt 2012, S. 42).

<b>Dimension</b>	<b>Beschreibung</b>
Feststellbarkeit	Störungen ... lassen sich feststellen.
Planabweichung	... sind quantitative, qualitative oder terminliche Abweichungen von einem geplanten oder erwarteten Systemzustand.
Prognostizierbarkeit	... lassen sich zeitlich nicht prognostizieren.
Unbeabsichtigkeit	... sind unbeabsichtigt und ungeplant.
Unregelmäßigkeit	... treten unregelmäßig auf.
Unvermeidbarkeit	... treten mit einer sich aus den relevanten Systemparametern ergebenden Wahrscheinlichkeit auf und lassen sich nicht vollständig vermeiden.
Verschlechterung	... haben eine negative Auswirkung auf den Systemzustand.
Vorhersehbarkeit	... lassen sich hinsichtlich ihrer Ursache-Wirkzusammenhänge grundsätzlich vorhersehen.
Zeitraumbezug	... treten während eines befristeten Zeitraums mit Eintritts- und Endzeitpunkt auf.

Beispiele für externe und interne Störeinflüsse finden sich an verschiedenen Stellen der Literatur. Interne Störeinflüsse umfassen unter anderem Aspekte wie eine mangelhafte Organisation (vgl. Abele et al. 2003, S. 174), eine nicht ausreichende Prozessreife neuer Technologien (vgl. Wiendahl et al. 2002, S. 653) sowie Toleranzen und Ungenauigkeiten in den Montageprozessen (vgl. Mannar und Ceglarek 2004, S. 41). Externe Störeinflüsse umfassen beispielsweise kurzfristige produktseitige Änderungen (vgl. Wiendahl et al. 2002, S. 654; Abele et al. 2003, S. 174; Ulrich 2016, S. 41), Probleme bei der Bereitstellung der Betriebsmittel durch Lieferanten (vgl. Abele et al. 2003, S. 174) sowie Informationsverluste bei der Verantwortungsübergabe zwischen den Organisationseinheiten in der Anlaufplanung (vgl. Wolgast und Carlson 2007, S. 925).

Abbildung 17 zeigt die vielschichtigen Ursachen von Anlaufhemmnissen nach Abele et al. (2003). Probleme bei Betriebsmitteln wie Produktionsmaschinen sind hier der dominierende

Punkt der identifizierten Anlaufhemmnisse. Werkzeugbau und Anlagenbau, insbesondere der Montageanlagen, rücken somit in den Fokus der Betrachtung.

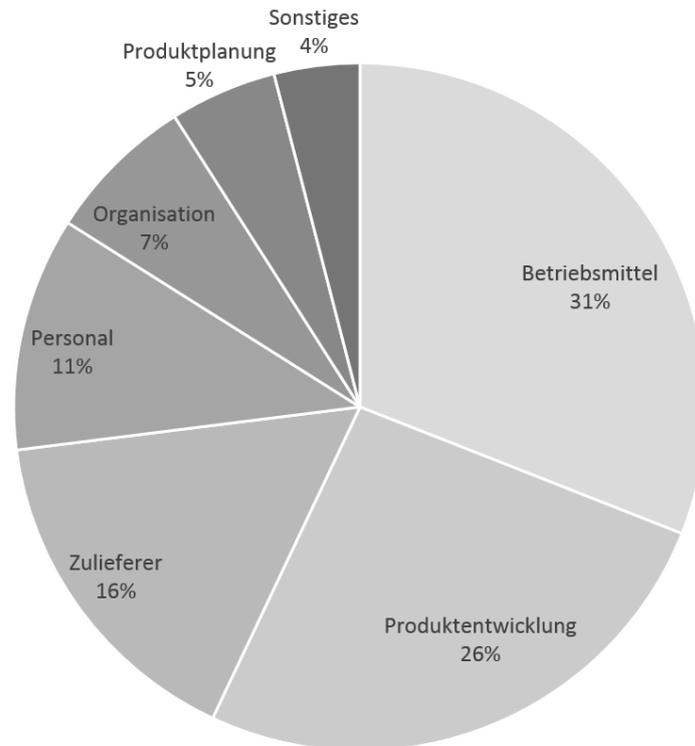


Abbildung 17: Anlaufhemmnisse nach (Abele et al. 2003).

Gemäß Kapitel 2.2.1 betrachtet der Produktionsanlauf einer Anlage die Phase der Inbetriebnahme plus Hochlauf. Im Umfeld automatisierter Prozessanlagen können dabei Unterschiede und Verzögerungen im Produktionsanlauf nicht über Lernkurven erklärt werden (vgl. Juering und Milling 2005, S. 4), sondern sind durchgängig auf Störungen zurückzuführen. Der Störungsbegriff lässt sich gemäß dem Betrachtungsfokus dieser Arbeit auf roboterbasierten Montageanlagen daher an dieser Stelle auf Anlagenstillstände und Fehler im Montageergebnis eingrenzen (vgl. Abbildung 18). Alle anderen Zustände einer roboterbasierten Montageanlage erfüllen die Anforderungen einer Störung im Produktionsanlauf entsprechend der Definition nach Bockholt (2012) und Nagel (2011) nicht.

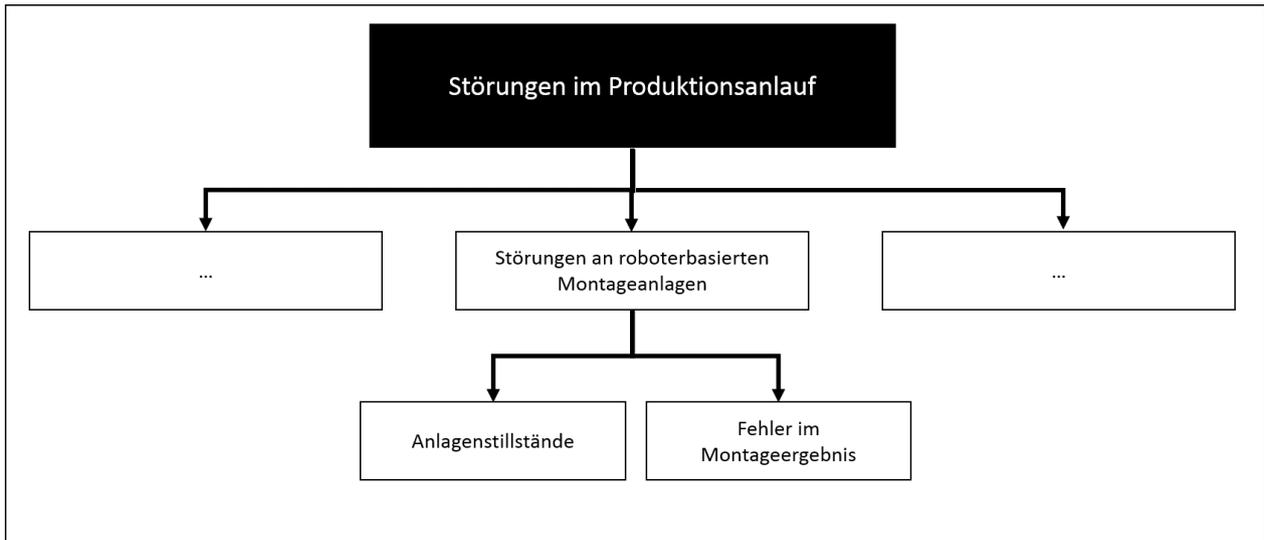


Abbildung 18: Abgeleiteter Störungsbegriff im Rahmen dieser Arbeit. Eigene Darstellung.

Unabhängig von dieser Eingrenzung ist ein lösungsorientierter Umgang mit diesen Störungen eine notwendige Anforderung zur Zielerreichung im Anlauf. Über eine detaillierte Planung können dabei nicht alle Störungen im Anlauf verhindert werden. In einer nach Wiendahl et al. (2002) durchgeführten Umfrage waren alle befragten Unternehmen der Ansicht, dass es nicht möglich ist, alle internen sowie externen Störeinflüsse durch eine noch bessere und detailliertere Planung im Vorfeld auszuschließen. Hieraus leitet sich die klare Forderung nach einer zunehmenden Störungsresistenz für Produktionssysteme im Anlauf ab.

Die möglichen Ursachen von Anlagenstillständen sind häufig sehr vielfältig und steigen mit der Anzahl an verbauten Komponenten einer Gesamtanlage (vgl. Heise 2010, S. 12). Dabei ist es auch möglich, dass eine direkte Korrelation zwischen einem Fehler im Montageergebnis und einem Anlagenstillstand existiert. Dies steht einer Anlaufzielerreichung gefährdend gegenüber.

Der in dieser Arbeit entwickelte Ansatz zur Selbstverbesserung einer roboterbasierten Montageanlage im Sinne einer zunehmenden Störungsresistenz beschränkt sich daher im weiteren Betrachtungsfokus rein auf den Störungsbegriff von messbaren Fehlern im Montageprozess.

## 2.3 Fehlervermeidung und Fehlervorhersage in der Produktionstechnik

In den vorgelagerten Kapiteln wurden an unterschiedlichen Stellen die besonderen Herausforderungen für neuartige Produktionsanlagen im Umfeld der Automobilendmontage aufgezeigt. Das Auftreten von Fehlern und den damit verbundenen Stillständen ist eine kritische Problemstellung im Anlauf, welche die Zielerreichung eines Produktionsanlaufs und damit verbunden auch häufig den wirtschaftlichen Erfolg eines Unternehmens gefährden kann (vgl. Kapitel 2.2). In diesem Kapitel werden bestehende Ansätze zu Vermeidung von Fehlern und Störungen in der modernen Produktionstechnik aufgezeigt und anschließend hinsichtlich ihrer Eignung für die Problemstellung dieser Arbeit eingeordnet.

### 2.3.1 Regelungstechnik

„Die Regelungstechnik befasst sich mit der Aufgabe, einen sich zeitlich verändernden Prozess von außen so zu beeinflussen, dass dieser Prozess in einer vorgegeben Weise abläuft“ (vgl. Lunze 2016, S. 1). In allen Fällen der Regelungstechnik muss eine von außen beeinflussbare Größe so angepasst werden, dass ein vorgegebenes Ziel erreicht wird. Dies erfolgt dabei in Abhängigkeit von der Zielerreichung. Dabei entsteht ein Regelkreis aus dem Prozess und einer zu schaffenden Einrichtung, dem Regler (vgl. Lunze 2016, S. 1).

Regelungssysteme scheinen somit grundsätzlich in der Lage zu sein, mit dem Einfluss externer Störgrößen auf einen Prozess umgehen zu können. Die Wissenschaft spricht in diesem Fall dann von intelligenten Regelsystemen. (vgl. Zacher und Reuter 2011, S. 361).

Der erfolgreiche Einsatz der Regelungstechnik an einer konkreten Aufgabenstellung erfordert die Auswahl, Formulierung und Modellierung der unterschiedlichen Größen und Zusammenhänge eines Regelkreises. Im nächsten Schritt erfolgt bei modellbasierten Verfahren die mathematische Modellierung der Regelstrecke. Der bedeutendste Teil der Analyse- und Entwurfsverfahren der Regelungstechnik bezieht sich auf die Erstellung dieses mathematischen Modells. Neben modellbasierten Verfahren existieren auch alternative Lösungswege von Regelungsaufgaben. Diese versuchen die aufwendige Modellbildung zu vermeiden und beabsichtigen den Regler stattdessen direkt am Prozess einzustellen (vgl. Lunze 2016, S. 17). Zacher und Reuter (2011) unterscheiden modellbasierte Regelungsalgorithmen von wissensbasierten Regelungsalgorithmen.

Wissensbasierte Regelungsalgorithmen bieten dann Vorteile, wenn eine physikalische Modellierung eines Prozesses sehr schwierig ist. In diesen Fällen können statistische Funktionsapproximatoren eingesetzt werden, die zur Nachbildung von Nichtlinearitäten geeignet sind, welche nur schwierig analytisch beschreibbar oder zugänglich sind (vgl. Schröder 2010, S. 37).

Die Fuzzy-Regelung und die Anwendung neuronaler Netze stellen nach Zacher und Reuter (2011) zwei besonders gängige Formen wissensbasierter Regelalgorithmen dar und werden daher in den folgenden Kapiteln neben modellbasierten Verfahren kurz vorgestellt.

### 2.3.2 Modellbasierte Verfahren

Modellbasierte Verfahren sind weit verbreitet (vgl. Ennen et al. 2016, S. 58) und finden sich an unterschiedlichen Stellen in der wissenschaftlichen Literatur, beispielsweise zur Regulierung von Brennstoffzellen (vgl. Golbert und Lewin 2004), zur Steuerung einer Insulinpumpe in der Medizintechnik (vgl. Parker et al. 1999) oder zur Bahnplanung von Roboterbewegungen (vgl. Reuter et al. 2014). Modellbasierte Verfahren beruhen dabei stets auf der möglichst genauen mathematischen Modellformulierung der Regelstrecke in einem Regelalgorithmus. Für modellbasierte Reglerverfahren ist somit zum einen das Vorliegen eines exakten mathematischen Modells der Regelstrecke Grundvoraussetzung. Zum anderen darf die Antwortzeit des Reglers durch die Bearbeitung über den Regelalgorithmus nicht stark verzögert werden (vgl. Zacher und Reuter 2011, S. 357).

### 2.3.3 Wissensbasierte Verfahren

#### **Fuzzy-Regelung**

Die Grundidee der Fuzzy-Regelung (fuzzy = engl. unscharf) ist der Verzicht auf eine eindeutige mathematische Beschreibung wie bei modellbasierten Regelungssystemen. Die eindeutigen Messgrößen werden hier beispielsweise nicht in numerischen Variablen mit Zahlen sondern über linguistische Variablen formuliert, die umgangssprachlichen Begrifflichkeiten wie „kalt“ oder „klein“ entsprechen können. Über diese unscharfe Logik kann auch für komplexe Systeme eine übersichtliche Darstellung ohne mathematische Beschreibung erfolgen (vgl. Zacher und Reuter 2011, S. 371).

Fuzzy-Regler arbeiten mittels sogenannter Fuzzy-Mengen. Für diese unscharfen Mengen ist keine eindeutige Zugehörigkeitsaussage für ein Element möglich, sondern lediglich die Angabe

eines Zugehörigkeitsgrads. Bei der Umsetzung in einem Regelsystem erfolgt dabei zunächst eine Übersetzung der gemessenen scharfen Werte der Eingangsgrößen in unscharfe Aussagen. Dieser Vorgang wird als Fuzzyfizierung bezeichnet. Hierauf erfolgt die Interferenz, eine Anwendung der Regeln auf die unscharfen Aussagen, und final die Umsetzung der unscharfen Regelergebnisse in scharfe Werte der Ausgangsgröße, was als Defuzzyfizierung bezeichnet wird (vgl. Schröder 2010, S. 773).

Ein großer Vorteil der Fuzzy-Regelung besteht dabei in einer hohen Robustheit. Fuzzy-Regelsysteme zeigen ein stabiles Verhalten auch dann wenn die Parameter der Regelstrecke nicht konstant sind (vgl. Zacher und Reuter 2011, S. 371). Ein weiterer Vorteil bietet sich überall dort, wo eine präzise mathematische Modellformulierung aufwendig oder nur schwer möglich ist (vgl. Yager und Zadeh 1992, S. 102). Jedoch ist auch für die Fuzzy-Regelung die Bekanntheit eines Reglergesetzes eine notwendige Grundvoraussetzung (vgl. Lunze 2016, S. 17), auch wenn diese verbal und weicher formuliert sein dürfen als bei der Anwendungen modellbasierter Verfahren. Zudem erfolgt die Optimierung von Fuzzy-Reglern über Probieren, was bei einer Vielzahl an Einflussmöglichkeiten sehr zeitaufwendig ist (vgl. Schröder 2010, S. 761).

### **Neuronale Netze**

Die Anwendung neuronaler Netze zur Identifikation unbekannter statistischer Funktionen ist kein grundsätzlich neues Konzept und geht bereits auf eine Phase noch vor den 1950er Jahren zurück (vgl. Schröder 2010, S. 38). Es handelt sich dabei um eine Form der Datenverarbeitung, die in ihrer Funktionsweise dem menschlichen Gehirn nachempfunden ist (vgl. Mühlhaus et al. 1999, S. 21). Dieses besteht aus einer großen Zahl einfacher Basiselemente, den Neuronen. Über eine umfassende Verknüpfung der Neuronen untereinander in mehreren Schichten wird eine parallele Datenverarbeitung großer Informationsmengen möglich (vgl. Poschmann 2000, S. 21).

Dabei werden Neuronen grundsätzlich in drei Klassen unterschieden (vgl. Abbildung 19): 1) Neuronen der Eingangsschicht, welche die zu verarbeitenden Informationen erhalten, 2) Neuronen der Ausgangsschicht, in denen sich die Resultate der Datenverarbeitung wiederfinden, sowie 3) Neuronen der sogenannten verborgenen Schichten, in welchen die Datenverarbeitung stattfindet. (vgl. Kotsiantis et al. 2007, S. 255)

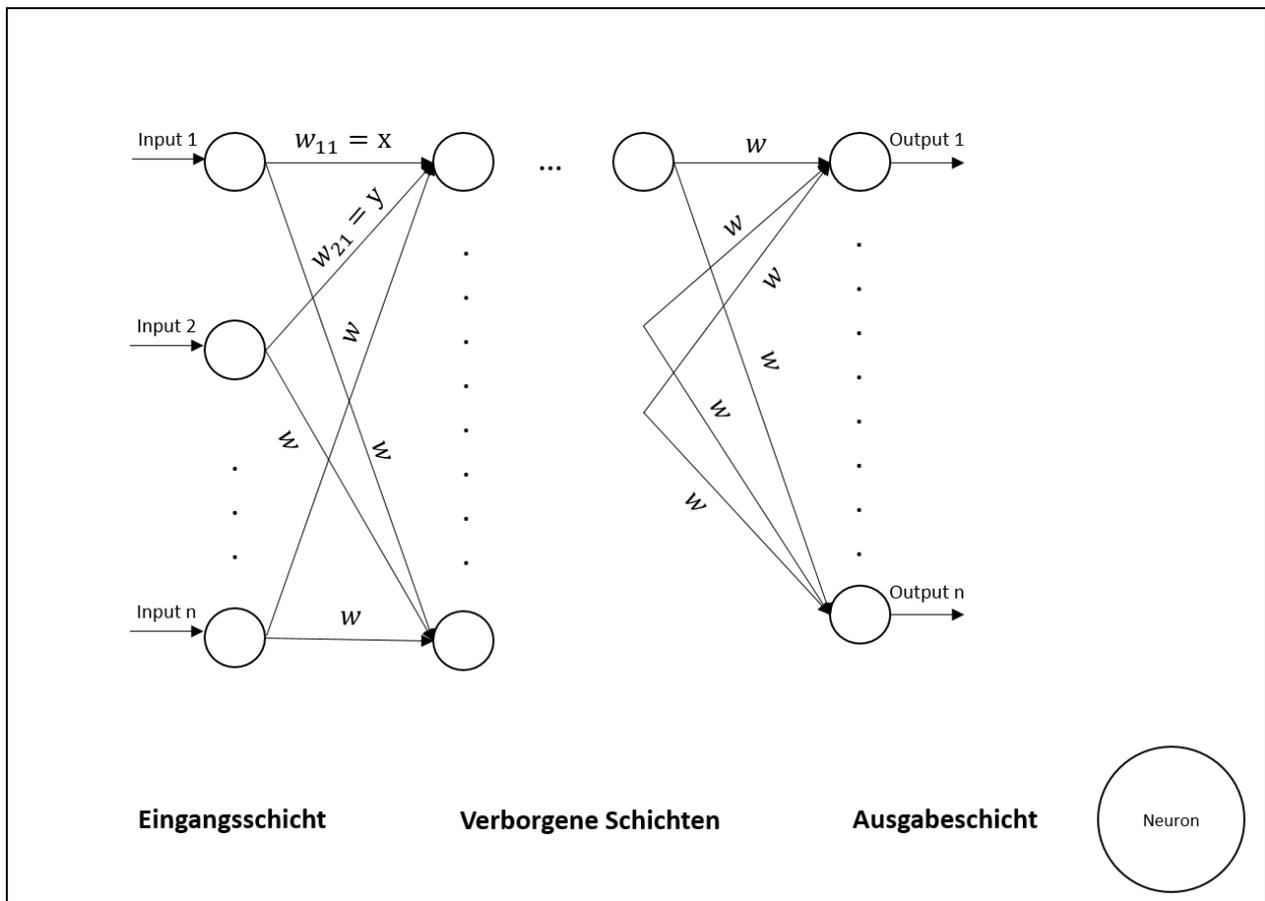


Abbildung 19: Grundstruktur künstlicher neuronaler Netze in Anlehnung an (Lippe 2006, S. 51) und (Jain et al. 1996, S. 38).

Künstliche neuronale Netze können dabei entweder als Feed-Forward-Netzwerke ausgeführt sein, in denen der Signalaustausch zwischen Neuronen nur in Richtung Eingangs- zu Ausgangsschicht erfolgen kann, oder als Feedback-Netzwerke, in welchen auch ein Signalaustausch innerhalb einer Schicht oder in Richtung Ausgang- zu Eingangsschicht möglich ist. (vgl. Jain et al. 1996, S. 35)

Moderne neuronale Netze sind lernfähig und werden über Trainingsdaten zunächst angeleitet, was ein besonderes Kennzeichen dieser Form der Algorithmen darstellt (vgl. Schröder 2010, S. 38; Mühlhaus et al. 1999, S. 494). Die Neuronen eines Netzes sind über gewichtete Verbindungen  $w$  mit den Neuronen der nächsthöheren Schicht verbunden (vgl. Abbildung 19). Durch eine systematische Veränderung dieser Gewichte mittels eines Lernalgorithmus können neuronale Netze die Zusammenhänge zwischen den Eingangs- und den Ausgangsgrößen erlernen und eine Abbildungsvorschrift herleiten (vgl. Mühlhaus et al. 1999, S. 495; Nauck et al. 1994). Neuronale Netze sind damit in der Lage komplexe Muster in Datenmengen zu erkennen und

zu verarbeiten. Eine Fähigkeit, die sich anwenden lässt, um das Verhalten einer Anlage oder eines Prozesses anhand von Prozessdaten zu erlernen (vgl. Mühlhaus et al. 1999, S. 495).

Ein weiterer Vorteil liegt darin, dass neuronale Netze somit nicht in konventioneller Art programmiert werden müssen und sie sich überall dort eignen, wo kein genaues Prozesswissen vorhanden ist (vgl. Poschmann 2000, S. 21).

#### 2.3.4 Exkurs maschinelle Lernverfahren

Datengetriebene Lernverfahren basieren auf dem Zugang zu einer existierenden, über eine Datenmenge repräsentierte Wissensbasis und stellen somit eine spezielle Unterform wissensbasierter Ansätze dar. Generell lassen sich datengetriebene maschinelle Lernverfahren (engl. Machine Learning) aus heutiger Sicht in die drei Kategorien „Supervised Learning“, „Unsupervised Learning“ und „Reinforcement Learning“ unterteilen (vgl. Alpaydin 2014, S. 9–13; Sugiyama 2015, xi). Eine Grundvoraussetzung für den Erfolg datengetriebener Ansätze liegt dabei immer in einer hohen Anforderung an die Qualität und Quantität der zur Verfügung stehenden Daten (vgl. Chiang et al. 2001, S. 6).

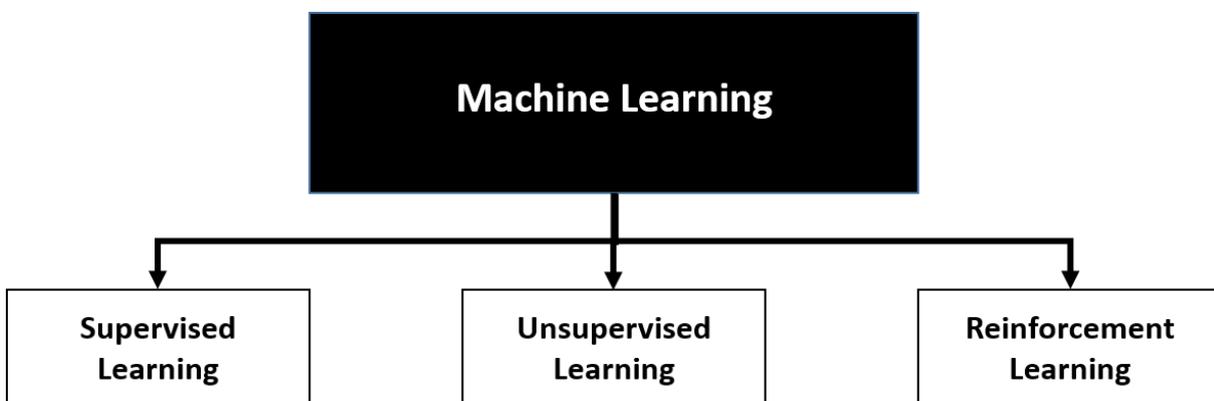


Abbildung 20: Übersicht Machine Learning in Anlehnung an (Sugiyama 2015) und (Alpaydin 2014).

#### **Supervised Learning (dt. überwachtes Lernen)**

Supervised Learning analysiert die Beziehung der Eingangs- und Ausgangsgrößen innerhalb einer Datenmenge. Grundvoraussetzung für die Anwendung von Supervised Learning ist damit immer die eindeutige Zuordnung und Kennzeichnung der betrachteten Datenmenge. Typische Aufgabenstellungen hierbei sind Klassifizierung, Regression oder Rangordnungsprobleme. (vgl. Alpaydin 2014, S. 9; Sugiyama 2015, xi; Suthaharan 2016, 7f.)

**Unsupervised Learning (dt. unüberwachtes Lernen)**

Im Falle von Unsupervised Learning ist die Datenmenge nicht eindeutig gekennzeichnet, Ergebnisse aber auch Klassengrenzen sind nicht bekannt. Den Algorithmen werden somit alleine die Eingangsgrößen für das Training gegeben, anhand derer Zusammenhänge erlernt werden sollen. Typische Aufgabenstellungen sind die Zusammenfassung ähnlicher Daten in Form von Clustering, Wahrscheinlichkeitsabschätzungen aber auch Datenvisualisierung. (vgl. Alpaydin 2014, S. 11; Sugiyama 2015, xi; Suthaharan 2016, S. 8)

**Reinforcement Learning (dt. bestärkendes Lernen)**

Im Falle von Reinforcement Learning werden dem System ebenfalls keine Ausgangsgrößen übergeben. Um aber dennoch die Beziehungen der Eingangs- mit den Ausgangsgrößen zu erlernen, werden sogenannte Nutzen- und Kostenfunktionen abgeleitet und optimiert. Über die Belohnung und Bestrafung korrekter und inkorrektter Aktionen erfolgt damit eine nur implizite Form des überwachten Lernens. (vgl. Sugiyama 2015, S. xi–xii; Ennen et al. 2016, S. 59)

## 2.4 Zusammenfassung der Vorbetrachtungen

In Kapitel 2 erfolgte die Erklärung und Diskussion relevanter Themengebiete für den weitergehenden Betrachtungsfokus der vorliegenden Arbeit und damit eine Eingrenzung und Erläuterung des notwendigen Kontextes dieser Arbeit.

Inhaltlich wurde dafür zunächst in Kapitel 2.1 das noch ungenutzte große Wirkpotential von Automatisierungstechnik in der Automobilendmontage aufgezeigt, sowie ein Einblick in die durch starre Verkettung geprägten Grundstrukturen der heutigen betrieblichen Praxis der Automobilendmontage gegeben. Im Umfeld dieser starren Verkettung haben häufig bereits geringe Störungen an einzelnen Stationen eine negative Auswirkung auf die Gesamtproduktivität einer kompletten Montagefabrik. Weiterhin konnte aufgezeigt werden, dass in diesem Umfeld in der Schwankung externer Einflussparameter eine besondere Herausforderung für den Innovationsprozess von der Ideengenerierung zur Ideenrealisierung zu liegen scheint. Dies äußert sich dabei aus Sicht der betrieblichen Praxis allen voran in der Überführung in den stabilen Serienbetrieb. Eine umfangreiche Absicherung im Vorhinein scheint dabei nicht immer praktikabel und es existiert folglich ein Bedarf an Lösungen, welche auch unter schwankenden externen Einflussfaktoren einen schnellen und stabilen Anlauf einer neuartigen roboterbasierten

Produktionstechnologie ermöglichen. Anschließend wurden mit sensitiven Robotern und cyber-physischen-Systemen zwei aktuelle Trends und Entwicklungen für die Produktionstechnik aufgezeigt, über die ein Teil des bisher noch ungenutzten Potentials in Zukunft nutzbar gemacht werden kann. Sensitive Roboter können dabei nicht nur sicher und schutzzaunlos mit dem Menschen an einer Station zusammenarbeiten, sondern ihre Sensitivität auch nutzen um nahezu alle Montageaufgaben in einem nur teilweise bekannten Umfeld sicher und präzise auszuführen. Mit der Übernahme von neuen Montageaufgaben durch sensitive Roboter, welche in der Vergangenheit aus Gründen der technischen Machbarkeit oder aus betriebswirtschaftlichen Gründen nur von Menschen übernommen werden konnten, ist mit einer rapiden Zunahme an roboterbasierten Montageprozessanlagen zu rechnen. Dabei werden die Tätigkeiten häufig das erste Mal von einem Roboter in einer Serienproduktion übernommen. Über den Trend einer zunehmenden Vernetzung und die Bildung cyber-physischer Produktionssysteme können entsprechende Werkzeuge und stabile Prozesse sowie eine Systematik zum schnellen und sicheren Anlauf der neuartigen Technologie entwickelt werden.

Im darauffolgenden Kapitel 2.2 wurde näher auf den Produktionsanlauf und das damit verbundene Anlaufmanagement eingegangen. Nach einem Überblick über den Umfang und die Strukturierung des Anlaufmanagements erfolgte ein Einblick in die allgemeinen Zielsetzungen. Anschließend konnte aufgezeigt werden, dass Produktionsanläufe häufig mit einer Anzahl an signifikanten Problemen wie (mangelnder) Produktqualität oder zeitlichem Verzug verbunden sind und daraus resultierend in den meisten Fällen weder die geplanten technischen noch wirtschaftlichen Zielsetzungen erreichen. Produktionsanläufe stellen dabei eine kostenintensive und kritische Phase dar. Aufgrund einer großen Anzahl unvorhersehbar auftretender Probleme ist ein stabiler Anlaufprozess in der betrieblichen Praxis eher selten. Die Erreichung der Zieldimensionen Zeit und Kosten ist unmittelbar mit einem schnellen Erreichen einer hohen Prozessstabilität und Prozessqualität der Montageanlagen im Anlauf verbunden. Da hierbei jedoch nicht alle möglichen Störeinflüsse über eine entsprechende Planung ausgeschlossen und beherrscht werden können, leitet sich auch hieraus erneut die notwendige Ausgestaltung einer Störungsrobustheit für Produktionssysteme im Rahmen eines zeitgemäßen Anlaufmanagements ab.

In Kapitel 2.3 wurden abschließend bestehende Ansätze zur Vermeidung von Fehlern und Störungen in der modernen Produktionstechnik aufgezeigt und hinsichtlich ihrer Eignung für die in Kapitel 2.1 und 2.2 aufgezeigte Problemstellung der vorliegenden Arbeit eingeordnet. Diese

unterscheiden sich in ihrer Sinnhaftigkeit dabei grundsätzlich stark anhand der jeweils vorhandenen Problemstellung sowie je nach Umfang und Art des vorhandenen Prozesswissens. Können aus physikalischen Abhängigkeiten klare mathematische Modelle beschrieben werden, so eignen sich zumeist modellbasierte Verfahren für intelligente Regelsysteme. Ist Prozesswissen mit einer gewissen Unschärfe und primär umgangssprachlich verbal formulierbar, bieten sich Vorteile durch den Einsatz der Fuzzy-Regelung. Bei neuartigen und komplexen Produktionsanlagen existiert jedoch häufig eine besondere Herausforderung dadurch, dass Teile des Prozesses sowie die Wechselwirkungen mit den Umfeldeinflüssen zum Zeitpunkt des Produktionsanlaufs häufig nicht in Gänze bekannt und damit weder quantitativ noch qualitativ beschreibbar sind. Viele Situationen ergeben sich im Produktionsanlauf das erste Mal und es fehlen die notwendigen Vorkenntnisse für eine ausreichend genaue Formulierung eines Regelgesetzes, sodass hier besonders datengetriebene Ansätze mit ihrer Fähigkeit zur eigenständigen Erkennung und Verarbeitung komplexer Muster geeignet erscheinen.

## **3 Anforderung an eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage**

### **3.1 Allgemeines**

Wie in Kapitel 1.1 beschrieben verkürzen sich aufgrund zunehmender Innovationen und immer kürzer werdender Produktlebenszyklen die Entwicklungszeiten für die Produkte sowie auch für die dahinter stehenden Produktionstechnologien. Dies hat nicht nur zur Folge, dass Produktionsanläufe neuer Produkte und neuer Technologien damit immer häufiger stattfinden, sondern führt auch dazu, dass in der Regel Produktionstechnologien zum Start der Inbetriebnahme einen niedrigeren Reifegrad aufweisen (vgl. Drath 2010, S. 16). Dies macht Anlagenstillstände im Anlaufprozess wahrscheinlicher und kann im Umfeld der starr verketteten Automobilendmontage zu größeren Anlaufverlusten in der Tagesproduktivität eines Fahrzeugwerks führen. Eine der Hauptherausforderungen für moderne Montagesysteme ist damit die kostenseitig getriebene Nachfrage nach schnellen und noch sichereren Anlaufprozessen (vgl. Michalos et al. 2010, S. 82). Die Anlaufsteuerung von Automatisierungsanlagen ist ein wesentlicher Bestandteil dieser Anlaufprozesse, welche, wie in Kapitel 2 dargelegt, von zunehmender Bedeutung für die Automobilendmontage der Fahrzeugproduktion werden wird. Hierfür werden in diesem Kapitel Anforderungen definiert, die eine zeitgemäße Anlaufsteuerung von roboterbasierten Automatisierungsanlagen in der Automobilendmontage zur Beherrschung der beschriebenen Herausforderungen erfüllen muss.

## 3.2 Anforderungsanalyse

In einer Untersuchung von Karl et al. (2011) hinsichtlich relevanter Kriterien für die Auswahl von Technologien in der betrieblichen Praxis wurden insgesamt 80 Rückmeldungen unterschiedlicher Unternehmen ausgewertet (vgl. Karl et al. 2011). Vorgelagerte Experteninterviews hatten hierzu bereits gezeigt, dass neben den klassischen Bewertungskriterien der technischen Machbarkeit und der Wirtschaftlichkeit die Technologiereife bei der Auswahl eines Produktionsverfahrens berücksichtigt werden muss. Anhand der Rückmeldungen erfolgte eine Rangfolge der Bewertungskriterien gemäß ihrer Wichtigkeit. Bei der Umfrage gaben 98,8 % der Unternehmen an, dass die Prozessstabilität und Prozesssicherheit besonders relevant bei der Auswahl von Technologien sei (vgl. Schindler 2015, S. 44). Die Anforderung Prozessstabilität und Prozesssicherheit wurde damit als wichtigster Einflussfaktor für die Auswahl einer Technologie bewertet.

Entsprechend der Zielsetzung und den Vorbetrachtungen dieser Arbeit (vgl. Kapitel 1 & 2 ) ist die frühe Erreichung einer hohen Prozessstabilität und Prozesssicherheit sowie die damit verbundene Störungsrobustheit einer neuartigen roboterbasierten Automatisierungsanlage eine der Kernaufgaben einer zeitgemäßen Anlaufsteuerung. Die Anlaufsteuerung muss dafür eine Reihe übergeordneter Anforderungen erfüllen, welche auf den folgenden Seiten genauer spezifiziert werden.

### **Anlaufrobust**

Ein System für eine zeitgemäße Anlaufsteuerung muss zur Störungsresistenz eines Produktionssystems im Anlauf beitragen. Ein System wird dabei dann als anlaufrobust bezeichnet, wenn es zum einen selbst keine Quelle für neue ungeplante Anlaufunsicherheiten ist und zum anderen die Fähigkeit besitzt, gesteuert, zielgerichtet und aufwandsarm auf ungeplante Ereignisse reagieren zu können (vgl. Wiendahl et al. 2002, S. 650). Um dieser Eigenschaft gerecht werden zu können, muss ein System neben der eigenen Stabilität somit über eine Reihe weiterführender Eigenschaften verfügen, die dem System eine passende Reaktion auf ungeplante Ereignisse ermöglicht. Hierfür folgen weitere Anforderungen, welche den Begriff der Anlaufrobustheit weiter detaillieren und ausbauen.

### **Wahrnehmend**

Damit ein System in der Lage ist auf Veränderungen und ungeplante Ereignisse reagieren zu können, muss es über eine Wahrnehmung dieser verfügen. Grundlage einer jeden Entscheidung und damit einer Reaktion ist immer die Wahrnehmung des realen Produktionssystems hinsichtlich dessen gegenwärtigen, vergangenen oder zukünftigen Zustands (vgl. Schmitt und Beaujean 2007, S. 522). Dies bedeutet, dass das System über entsprechende Sensoren verfügen muss, über die eine Umwandlung nicht elektrischer Signale in elektrische Signale erfolgt und die somit dem System eine Wahrnehmung aller relevanter Einflüsse und Zustände sowie die Fähigkeit zur Interpretation dieser Daten ermöglichen (vgl. Heinrich et al. 2015, 30ff.).

### **Entscheidend**

Eine wesentliche Voraussetzung für die Reaktion eines Systems auf Veränderungen oder Störungen im Anlaufprozess ist die Fähigkeit zur eigenständigen Entscheidung und Ausführung einer Reaktion. Wie in Kapitel 2.3 aufgezeigt existieren hierfür unterschiedliche Ansätze, um Systeme über die Formulierung entsprechender Regeln entscheidungsfähig zu gestalten. Die Algorithmen zur Entscheidungsfindung bilden den Kern moderner Automatisierungssysteme und beinhalten Logiken, über die eine Findung, Bewertung und Auswahl der Entscheidungsalternativen erfolgt. Die Fähigkeit selbstständiger Entscheidungsfindungen technischer Systeme ist eine der Grundvoraussetzungen um Produktionssysteme intelligenter zu gestalten (vgl. Schmitt und Beaujean 2007, S. 522) und damit auch eine Anforderung für die Gestaltung einer zeitgemäßen Anlaufsteuerung.

### **Vorhersagend & Vermeidend**

Eine weitere wesentliche Anforderung an eine zeitgemäße Anlaufsteuerung ist die Fähigkeit, den negativen Einfluss von unerwartet auftretenden Störgrößen und Unsicherheiten vorherzusagen und diesen im Anlauf auf ein mögliches Minimum zu reduzieren. Hierfür muss das System in der Lage sein über die Auswahl einer entsprechend adäquaten Reaktion das Auftreten von Fehlern und Störungen zu vermeiden. Nach Pfeifer (1996) verursacht ein Fehler mit jeder Phase, in der dieser später mit Bezug zu seinem Entstehungszeitpunkt entdeckt und beseitigt wird, um den Faktor 10 höhere Kosten hinsichtlich seiner Auswirkungen. Eine Fehlervermeidung ist damit stets gegenüber einer späteren Fehlerentdeckung und Fehlerbehebung zu bevorzugen.

Ziel der Fehlervermeidung ist die Reduzierung auftretender Fehler auf ein mathematisches Minimum von null Fehlern. Die Fehlervermeidung geht somit über die Fehlerentdeckung hinaus und bewirkt eine Optimierung von Produktionsprozessen (vgl. Fritz 2007, S. 18).

### **Kurzfristig Wirksam**

Da es sich beim Produktionsanlauf von Automatisierungsanlagen in der Automobilendmontage um eine zeitliche begrenzte Phase bestehend aus Inbetriebnahme und Hochlaufphase handelt, muss das System zur Anlaufsteuerung in möglichst kurzer Zeit auf unbekannte Veränderungen und Störeinflüsse vermeidend reagieren können. Das Erreichen der Kammlinien im Produktionsanlauf in der Automobilindustrie kann dabei nach einem Zeitraum von nur wenigen Wochen erfolgen (vgl. Renner und Dyckhoff 2012, S. 22). Hierfür muss das System zum einen in der Lage sein die Reaktionszeit auf Störungen und Änderungen kurz zu gestalten, was wiederum einer schnellen Entscheidung und Einleitung einer passenden Reaktion entspricht. Zum anderen muss das System über die Auswahl einer möglichst effektiven Reaktion die Zeit bis zur positiven Prozessbeeinflussung verkürzen.

### **Selbstlernend & Anpassungsfähig**

Eine große Herausforderung für die Gestaltung und den Betrieb von Systemen zur Anlaufsteuerung liegt in der aufwandsarmen Gestaltung dieser Systeme. Wie in Kapitel 2.3 aufgezeigt ist die Ausarbeitung mathematischer Steuerungskonzepte und Regelstrecken in den meisten Fällen mit einem größeren Aufwand verbunden. Viele der im Anlauf auftretenden Störeinflüsse sind zudem im Zeitraum der Anlaufphase nicht bekannt und viele auftretende Wirkzusammenhänge können vorab nicht in Reglergesetzen formuliert werden. Im Falle eines Systems, welches eine sprachliche oder mathematische Modellierung der Regelstrecke erfordert, muss eine aktive Analyse der unerwartet auftretenden Störgrößen und Wirkzusammenhänge erfolgen und eine darauffolgende Anpassung und Erweiterung der hinterlegten Reglergesetze stattfinden. Die Ausführung als selbstlernendes System hingegen führt zu einer besonders aufwandsarmen Gestaltung und Betrieb. Selbstlernende Systeme können dabei Zusammenhänge zwischen den Eingangs- und den Ausgangsgrößen erlernen und somit über einen Zeitraum, auch bei sich stetig verändernden Störeinflüssen, eigenständig zur verbesserten Systemperformance im Produktionsanlauf beitragen.

### 3.3 Leitsätze für eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage

Die Ausgestaltung von Leitsätzen ist eine Möglichkeit der Gestaltung eines gesamten Produktionssystems oder der darunter liegenden Verfahren zur Steuerung von Produktionstechnologien (vgl. Deuse et al. 2007; Engelhardt 2015, S. 29; Lödding 2008). Im Folgenden werden Leitsätze für eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage definiert, welche eine Ergänzung und Konkretisierung der formulierten Anforderungen darstellen.

- Das System ist in der Lage relevante Veränderungen in den Umfeldeinflüssen der roboterbasierten Automatisierungsanlage wahrzunehmen. Hierzu zählen Veränderungen des verwendeten Materials, Veränderungen der Umgebungsbedingungen und auch Ungenauigkeiten in den vorgelagerten Prozessen.
- Innerhalb dieser Einflussfaktoren erkennt das System eigenständig Muster, die eine negative Auswirkung auf das Montageergebnis haben.
- Das System lernt für entsprechende Muster aus einem Set von möglichen Gegenmaßnahmen, welche Maßnahmen einen Fehler im Montageergebnis vermeiden und leitet diese zukünftig zur Fehlervermeidung ein.
- Das System bleibt dabei eigenständig anpassungsfähig. Veränderungen der Einflussgrößen verursachen keinen zusätzlichen manuellen Programmieraufwand.
- Das System lernt die Muster innerhalb eines Zeitraums, der zu einer signifikanten Performanceverbesserung im Rahmen einer industriüblichen Anlaufdauer beiträgt.

## 4 Stand der Forschung und Technik

### 4.1 Überblick

Das folgende Kapitel beschreibt den aktuellen und relevanten Stand der Forschung und Technik hinsichtlich der Zielsetzung der vorliegenden Arbeit und baut dabei auf den in Kapitel 2 definierten Grundlagen und Vorbetrachtungen sowie auf den in Kapitel 3 formulierten Anforderungen auf.

Kapitel 4.2 gibt einen Überblick zu in der Breite existierenden Ansätzen für das Anlaufmanagement in der Automobilindustrie. Aufbauend auf diesen Erkenntnissen und vor dem Hintergrund der Zielsetzung dieser Arbeit widmet sich Kapitel 4.3 der tiefgreifenden Betrachtung von Ansätzen zum Umgang mit Störungen des Produktionsanlaufs. In Kapitel 4.4 folgt dann aufbauend auf den vorherigen Abschnitten die Diskussion existierender Handlungsbedarfe und eine Abgrenzung dieser Arbeit vom aktuellen Stand der Forschung und Technik.

### 4.2 Anlaufmanagement in der Automobilindustrie

Wie in Kapitel 2 dieser Arbeit aufgezeigt, besteht die Aufgabe des Anlaufmanagements in der Koordination zielführender Aktivitäten des Produktionsanlaufs und damit auch in der Entzerrung und Beherrschung technischer und organisatorischer Störungen in der Anlaufphase (vgl. Schmitt 2015, S. 3).

In der wissenschaftlichen Literatur finden sich zahlreiche unterschiedliche Ansätze und Methoden zum Anlaufmanagement in der Automobilindustrie. Surbier et al. (2014) unterteilt diese (vgl. Abbildung 21) in „kennzahlorientierte Ansätze“, „Ansätze basierend auf Ursache-Wirkungs-Analysen“, „Ansätze basierend auf Kommunikation und Informationsaustausch in der Anlaufphase“ und „ganzheitliche Ansätze“. Basierend auf einer umfangreichen Literaturrecherche zum Anlaufmanagement wird an dieser Stelle auf der gemachten

Unterteilung aufgebaut und diese noch um die zusätzliche Kategorie „selbstlernender Ansätze“ erweitert. Da die nach Surbier et al. (2014) vorgestellten Ansätze basierend auf Ursache-Wirkungs-Analyse im Gesamtkontext auch immer zur Ableitung relevanter Kennzahlen verwendet werden, erfolgt in dieser Arbeit eine Integration dieser Ansätze in die Kategorie der kennzahlorientierten Ansätze.

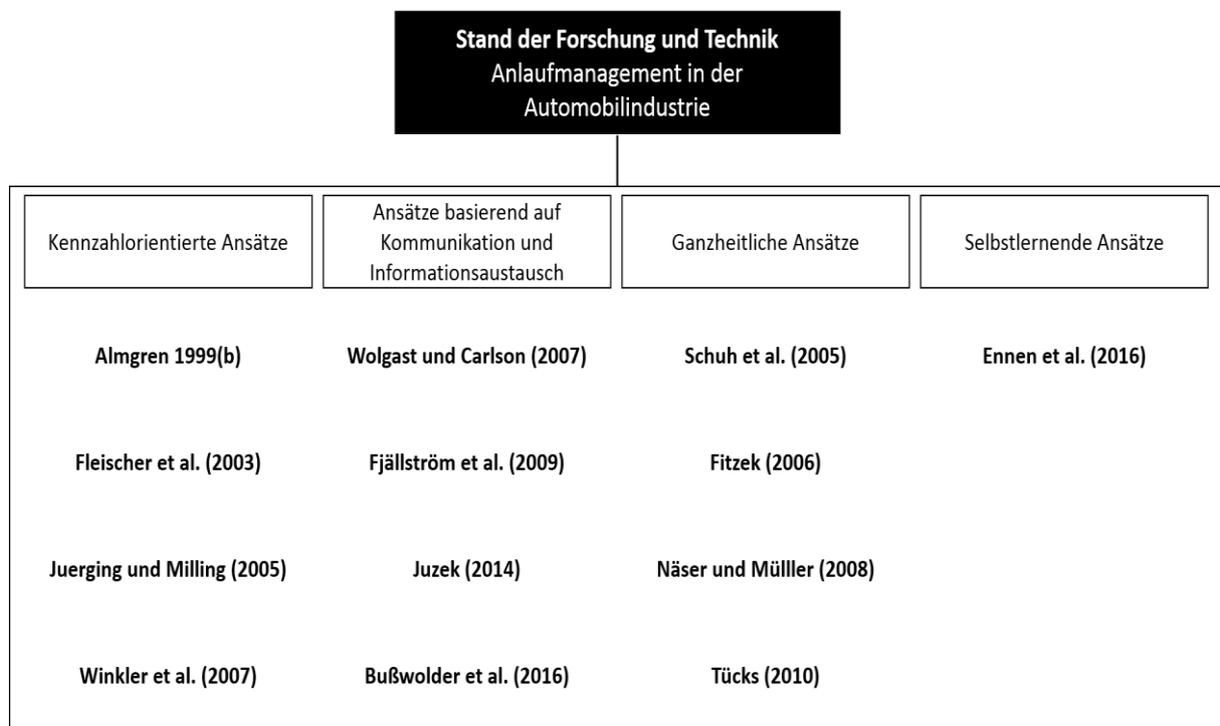


Abbildung 21: Existierende Ansätze Anlaufmanagement in der Automobilindustrie. Eigene und erweiterte Unterteilung basierend auf (Surbier et al. 2014).

#### 4.2.1 Kennzahlorientierte Ansätze

Die Grundidee kennzahlorientierter Verfahren ist zunächst die Schaffung von Transparenz über die Auswahl der richtigen Betrachtungsgröße sowie eine Erleichterung bei der Entscheidungsfindung und bei der Bewertung möglicher Maßnahmen. Über eine kontinuierliche Betrachtung der Kennzahlen kann zum einen die Kontrolle des Grades der Zielerreichung von Maßnahmen und Strategien sowie eine Steuerung betrachteter Bereiche erfolgen. (vgl. Ossola-Haring et al. 2016, 67ff.)

Hierbei kommt, neben der Aktualität und Darstellung einer Kennzahl, vor allem der Auswahl der richtigen Betrachtungsgröße eine besondere Bedeutung zu (vgl. Schuh und Stich 2012, 16ff.).

*Towards a framework for analyzing efficiency during start-up* nach Almgren (1999b)

Almgren (1999b) leitet über die Betrachtung einer durchgeführten Fallstudie aus der Automobilproduktion des Volvo S70 Faktoren ab, welche die Ausbringungsmenge und damit die Effizienzrate während des Anlaufs beeinflussen. Der Autor fokussiert sich dabei auf eine empirische Beweisführung und identifiziert die vier unabhängigen Einflussgrößen „Arbeitsmethode“, „Arbeitstempo“, „Prozessstörgrößen“ und „Produktanpassung“. Almgren geht dabei von der Grundthese aus, dass Produktionssysteme im Anlauf intern und extern bedingten Störgrößen unterliegen, welche Kapazitäts- und Qualitätsverluste zur Folge haben und vom Autor als entstehende Kosten betrachtet werden. Über die Anwendung eines ingenieurwissenschaftlichen Kostenmodells sowie Indices für die Qualitäts- und Kapazitätsleistung wird die Veränderung der Effizienzrate im Anlauf untersucht.

Das von Almgren (1999b) entwickelte Bezugssystem konzentriert sich stark auf die Identifikation unabhängiger Handlungsfelder zur Steigerung der Anlaufperformance und dient daher primär als Managementinstrument zur Fokussierung von Vorbereitungsaktivitäten eines Produktionsanlaufs.

*Quality simulation for fast ramp-up* nach Fleischer et al. (2003)

In Fleischer et al. (2003) wird die Qualität als Kennzahl in den zentralen Betrachtungsfokus der Untersuchung gestellt. Die Autoren stellen hierfür ein Konzept der Qualitätssimulation vor. Dieses basiert auf der Ableitung einzelner erwarteter Qualitätspotentialkurven im instabilen Zustand des Produktionsanlaufs, sowie einer Überführung dieser in eine globale Qualitätspotentialkurve. Zur aufwandsarmen Anwendbarkeit basieren die hinterlegten Qualitätsfunktionen dabei auf standardisierten Grundprozessen.

Fleischer et al. (2003) fokussieren sich stark auf den Aspekt der Qualitätszielerreichung. Über die Ableitung der erwarteten Qualitätspotentialkurven können vor und während eines Produktionsanlaufs frühzeitig Zielabweichungen erkannt werden. Die Bewertung und Entscheidung passender Maßnahmen erfolgt dabei rein über den Menschen. Durch die Einrichtung von Kontrollzyklen findet eine Anpassung der Qualitätssimulation auf real aufgetretene Störungen während des Anlaufs statt. Der Umgang mit Störungen ist somit rein reaktiv. Eine selbständige Optimierung der hinterlegten Qualitätsfunktionen für die Simulation ist nicht realisiert.

*Interdependencies of product development decisions and the production ramp-up* nach Juerging und Milling (2005)

Auch Juerging und Milling (2005) analysieren den Produktionsanlauf aus einer Qualitätsperspektive und betrachten zusätzlich zwei mögliche Strategien zum Umgang mit notwendigen Anpassungen und Änderungen während des Produktionsanlaufs. Der Produktionsanlauf wird dafür mittels eines dynamischen Systemmodells abgebildet und es werden dabei Produktionsprozesse sowie Lernkurveneffekte berücksichtigt. Die Autoren kommen zur Erkenntnis, dass die produzierte Qualität stark vom Zeitpunkt des Produktionsstarts in Bezug auf den Entwicklungsbeginn abhängt. Ein sehr früher Produktionsbeginn hat somit häufig gesamthaft Nachteile gegenüber einem Produktionsbeginn zu einem späteren Zeitpunkt, da aufgrund unreifer Produkte das Erreichen der Kammlinie länger verzögert wird und zusätzlich im Anlauf große Aufwände zur Produkt- und Prozessanpassung entstehen. Nach Juerging und Milling (2005) muss das Kernziel eines Produktionsanlaufs daher nicht ein möglichst früher Produktionsbeginn sondern vielmehr ein möglichst frühes Erreichen des Kapazitätsziels auf der Kammlinie sein. Die vorteilhafteste Strategie liegt somit in der Auswahl eines gemäßigten Zeitpunkts zum Start der Serienproduktion und einer damit verbundenen mittelhohen Rate notwendiger paralleler Aktivitäten zwischen Entwicklung und Produktion.

Der vorgestellte Ansatz nach Juerging und Milling (2005) legt einen starken Betrachtungsfokus auf die Produkt- und Prozessreife zum Zeitpunkt des Produktionsanlaufs und liefert damit eine Planungsunterstützung zur Auswahl eines möglichst optimalen Zeitpunkts zum Start der Serienproduktion. Da es aus Sicht der Autoren aber bei einem entsprechend hohen Reifegrad durchaus immer noch zu notwendigen Produkt- und Prozessänderungen kommt, geben die Autoren hierfür Richtlinien für den Umgang in Abhängigkeit vom Innovationsgrad des neuen Produktes und damit auch für die Ausgestaltung der Anlaufsteuerung. In allen Fällen gehen die Autoren aber immer von einer reaktiven Anpassung auf auftretende Probleme aus. Eine Fehlervermeidung im Anlauf wird somit nur indirekt über die Auswahl des Zeitpunktes für den Produktionsstart berücksichtigt.

*A controlling system based on cause-effect relationships for the ramp-up of production systems* nach Winkler et al. (2007)

Winkler et al. (2007) stellen in ihrer Arbeit die Entwicklung eines Anlaufsteuerungssystems vor, welches auf einem Prognosemodell der Zielgrößen Leistung, Kosten und Fälligkeitsterminen beruht. Die Prognosewerte werden hierbei über die Aufstellung von Ursache-Wirkungs-Beziehungen zwischen den sich verändernden Parametern und den genannten Zielgrößen abgeleitet. Das entwickelte System erfüllt seinerseits die Funktionalitäten:

- einer prompten Detektion und Transparenz über die aktuelle Anlaufsituation,
- einer Problemevaluation,
- einer Prognose und Erprobung entsprechender Alternativmaßnahmen
- sowie die Erbringung effektiver Reaktionsstrategien.

Der von Winkler et al. (2007) vorgestellte Ansatz fokussiert die Prognose signifikanter Produktionsparameter im Anlauf. Hauptziel ist dabei die Beschleunigung und Unterstützung von Entscheidungsprozessen der im Produktionsanlauf involvierten entscheidungsberechtigten Teilnehmer.

#### 4.2.2 Ansätze basierend auf Kommunikation und Informationsaustausch

Neben den bereits vorgestellten kennzahlgetriebenen Ansätzen finden sich in der wissenschaftlichen Literatur weitere Ansätze, die den Austausch von Informationen und die Kommunikation in den Vordergrund der Betrachtung stellen.

*Running changes and re-design in the auto industry: An exploratory study of engineering and knowledge transfer after start of production* nach Wolgast und Carlson (2007)

Wolgast und Carlson (2007) untersuchen im Rahmen einer Studie die Einflüsse von Kommunikationsmustern und den Wissenstransfer hinsichtlich kontinuierlicher Veränderungen nach dem Produktionsstart in der Automobilindustrie. Die Autoren kommen dabei zu dem Schluss, dass die hohe Komplexität innerhalb der untersuchten Organisation ein Hemmnis für effektive Feedbackschleifen darstellt. Dies führt häufig zu einem Mangel an Kommunikation und Information der beteiligten Parteien. Eine wesentliche Erkenntnis der Studie ist, dass es häufig zu einem Informationsverlust bei der Informationsübergabe zwischen den zu unterschiedlichen Zeitpunkten beteiligten Organisationseinheiten kommt.

Hierfür entwickeln die Autoren eine Prozesslandkarte sowie eine Handlungsschritt-kette, welche zu einer Verbesserung des Wissenstransfers zwischen den unterschiedlichen beteiligten Parteien beitragen sollen.

Dieser Ansatz nach Wolgast und Carlson (2007) betrachtet somit besonders den notwendigen Informationsaustausch zwischen der realen Produktion und dem Produktdesign sowie den Fertigungsingenieursabteilungen. Der Ansatz umfasst damit auch zu Teilen die Anlaufsteuerung, beschränkt sich dabei jedoch ausschließlich auf die Rückkopplung der realen Produktionserkenntnisse als Einflussgröße für die Gestaltung kommender Produkte und der damit verbundenen Fertigungstechnik. Der Einfluss externer Störgrößen sowie der aktive Umgang mit diesen negativen Effekten im Anlauf werden nicht betrachtet.

*Information enabling production ramp-up* nach Fjällström et al. (2009)

Fjällström et al. (2009) untersuchen die Rolle von Informationen hinsichtlich auftretender kritischer Ereignisse während eines Produktionsanlaufs in der Automobilindustrie. Basierend auf einer durchgeführten Fallstudie bei einem schwedischen Automobilhersteller werden zunächst aus allen beobachteten Ereignissen jene 30 Ereignisse ausgewählt, welche einen besonders kritischen Einfluss auf den Produktionsanlauf hatten. Die Auswahl der Ereignisse erfolgt dabei basierend auf Experteninterviews während des Anlaufs. Die Ereignisse werden anschließend in die sechs Kategorien „Zulieferer/Versorgung“, „Produkt/Qualität“, „Anlagen/Technik“, „Prozess, Personal/Ausbildung“ und „Organisation“ unterteilt. Anhand dieser Unterteilung untersuchen die Autoren welche Informationsquelle und Informationsart im Umgang mit dem aufgetretenen kritischen Ereignis am hilfreichsten war. Hierfür unterteilen die Autoren die drei Informationsarten in „generelle Information zum Wissensgebiet“, „spezifische Probleminformation“ und „Problemlösungsinformation“. Die Autoren kommen zu dem Ergebnis, dass unabhängig von der jeweiligen Ereigniskategorie eine ausgewogene Mischung aus genereller Information zum Wissensgebiet und Probleminformation am nützlichsten für den Umgang mit dem aufgetretenen kritischen Ereignis ist. Die bevorzugte Informationsquelle ist dabei unabhängig von der Eventkategorie immer „andere Leute“, wobei die Autoren dem informellen Informationsaustausch innerhalb einer Anlauforganisation eine besonders hohe Bedeutung zuweisen.

Ziel der durchgeführten Analyse nach Fjällström et al. (2009) ist damit die Identifikation des richtigen Informationstyps und der jeweils richtigen Informationsquelle für einen möglichst effizienten Umgang mit auftretenden kritischen Ereignissen während des Produktionsanlaufs. Die gemachten Erkenntnisse basieren hierbei auf einem konkreten Auftreten eines kritischen Ereignisses während der Anlaufphase. Es handelt sich dabei also um eine rein reaktive Betrachtungsperspektive im Umgang mit einer bereits aufgetretenen Störung. Eine Ableitung fehlervermeidender Maßnahmen und auch eine Selbstoptimierung anhand bereits aufgetretener Probleme werden dabei von den Autoren nicht berücksichtigt.

*Entwicklung eines automatisierten, ontologiegestützten Wissensmanagementmodells für Produktionsanläufe in der Automobilindustrie* nach Juzek (2014)

Juzek (2014) stellt die Rolle des Wissensmanagements für den Produktionsanlauf in das Zentrum seiner Betrachtung. Ausgehend von der Erkenntnis einer häufig nicht ausreichenden Problemlösungskompetenz der beteiligten Produktionsmitarbeiter im Anlauf entwickelt der Autor ein automatisiertes Wissensmanagementmodell, basierend auf der Anwendung des fallbasierten Schließens.

Über eine Speicherung neuartiger Lösungen in einer Falldatenbank wird dabei eine zunehmende Verbesserung und Entwicklung des Systems realisiert. Der verfolgte Ansatz ist dabei rein reaktiv und dient in der Entscheidungsfindung einer möglichst schnellen Problem- und Störungsbeseitigung nach ihrem Auftreten.

*Classification of Company-specific Influence Factors as Part of a Knowledge Management System for Ramp-up Projects* nach Bußwolder et al. (2016)

Bußwolder et al. (2016) beschäftigen sich mit der Entwicklung eines speziell auf den Produktionsanlauf zugeschnittenen Wissensmanagementsystems. Die Autoren verfolgen in ihrem Ansatz als Hauptziel die Identifikation jener Einflussfaktoren, die den Erfolg eines Anlaufs bestimmen. Die Wissensgenerierung erfolgt über Experteninterviews der unterschiedlichen am Anlauf beteiligten Organisationseinheiten und einer Auswertung dieser Daten über einen paarweisen Vergleich. Über eine Rückführung der Ergebnisse vergangener Produktionsanläufe steigt dabei die Genauigkeit des Wissensmanagementsystems mit zunehmender Anzahl an Anläufen.

Der vorgestellte Ansatz ist dabei aus Sicht der Autoren selbst ein nur erster Schritt zur Entwicklung eines generischen Wissensmanagementsystems für den Anlauf. Bußwolder et al. (2016) beschränken sich rein auf die Vorstellung einer Methodik, konkrete Erkenntnisse und Erfahrungen aus der betrieblichen Praxis werden nicht vorgestellt. Auch eine Systematik zum Umgang mit Störeinflüssen während des Anlaufs erfolgt nicht. Die Arbeit legt somit vielmehr einen Grundstein für die weitere Entwicklung und Ausgestaltung zum Umgang mit Störgrößen im Anlauf aus einer Perspektive des Wissensmanagements.

#### 4.2.3 Ganzheitliche Ansätze

*Holistic Approach for Production Ramp-Up in Automotive Industry* nach Schuh et al. (2005)

Schuh et al. (2005) betrachten den Produktionsanlauf in der Automobilproduktion aus einer ganzheitlichen Perspektive. Der darin vorgestellte Ansatz basiert auf einer Unterteilung des Anlaufmanagements in die drei Stufen Anlaufstrategie, Anlaufplanung (und Realisierung einer passenden Strategie im Bereich der Produktion) sowie Anlaufbewertung. Die Autoren stellen insgesamt vier unterschiedliche Anlaufstrategien vor, die jeweils unterschiedliche Vor- und Nachteile hinsichtlich der Entwicklung des Produktionsvolumens im Anlauf über die Zeit hinweg haben.

Der Ansatz nach Schuh et al. (2005) fokussiert sich sehr stark auf den Verlauf der Anlaufkurven über die Auswahl der passenden Anlaufstrategie. Über eine Entzerrung des parallelen Anlaufs mehrerer Modellvarianten bietet der Ansatz eine Möglichkeit zur Komplexitätsreduzierung und damit zur besseren Beherrschung eines Produktionsanlaufs. In der Anlaufplanung und Realisierung der Anlaufstrategie setzen sich die Autoren mit einer notwendigen Flexibilität hinsichtlich etwaiger produktbedingter Änderungen im Anlauf auseinander. Die Anlaufbewertung zielt auf eine kontinuierliche Verbesserung der Anlaufplanung ab und berücksichtigt auch existierende Lieferantenstrukturen. Der Aspekt der Anlaufsteuerung unter Einfluss von Störgrößen wird nicht berücksichtigt.

*Anlaufmanagement in Netzwerken: Grundlagen, Erfolgsfaktoren und Gestaltungsempfehlungen für die Automobilindustrie* nach Fitzek (2006)

Fitzek (2006) identifiziert Erfolgsfaktoren und Gestaltungsempfehlungen für ein verbessertes Anlaufmanagement im automobilen Produktionsnetzwerk. Der Autor berücksichtigt dabei sowohl die vertikale Produktionsnetzwerkdimension zwischen Zulieferer und OEM als auch die horizontale Dimension des Produktionsnetzwerks. Anhand der Untersuchung mehrerer Serienanläufe werden dabei die Erkenntnisse empirisch abgeleitet und aufgestellte Thesen überprüft. Fitzek (2006) kommt zur wesentlichen Erkenntnis, dass interorganisationales Lernen und Planen von besonderer Bedeutung für den Erfolg eines Anlaufs sind.

Der Autor leitet anhand der gemachten Analysen anschließend Gestaltungsempfehlungen für das Management von Produktionsanläufen entlang der verschiedenen Dimensionen ab. Der Umgang mit Störeinflüssen sowie die Verhinderung der damit verbundenen Anlaufstillstände werden nicht betrachtet.

*Steuerung des Anlaufmanagements mit komplexen Regelkreisen* nach Näser und Müller (2008)

Näser und Müller (2008) stellen in ihrer Arbeit die Idee einer Anwendung reaktiver sowie präventiver Regelkreise zur Ausgestaltung von Anlaufmanagementprozessen für Montagesysteme in der Endmontage der Automobilindustrie vor. Als Anwendungskonzept wird die Entwicklung eines Anlaufnavigators aufgezeigt, welcher in der Anlaufplanung genutzt werden kann. Der Navigator besteht dabei aus zwei Teilen: aus einem Handbuch zur Planung und Gestaltung des Anlaufmanagements und aus einem Werkzeug, das eine Bewertung der Anlaufmanagementprozesse unterstützt. Über diese Bewertung wird die Überwachung und Steuerung der Zielgrößen erleichtert.

Näser und Müller (2008) gehen in ihrem Ansatz davon aus, dass bezüglich auftretender Anlaufstörungen ein Problembereich sowie ein Gestaltungsbereich definiert werden kann. Dieser Ansatz berücksichtigt somit keine unerwartet auftretenden Störungen oder Störungen, die aufgrund unbekannter Wirkzusammenhänge mit den Veränderungen des Umfelds ausgelöst werden. Auch das Konzept einer eigenständigen Fehlervorhersage und Fehlervermeidung auf Anlagenebene wird nicht betrachtet.

*Ramp-up-Management in der Automobilindustrie* nach Tücks (2010)

Tücks (2010) betrachtet den Produktionsanlauf in der Automobilindustrie ganzheitlich und berücksichtigt dabei Elemente über die gesamte Dauer eines Produktionsanlaufs hinweg von der Anlaufplanung über die Anlauforganisation bis hin zur Anlaufsteuerung auf Maschinenebene. Der Autor entwickelt im Rahmen der Arbeit unterschiedliche Module, die in der betrieblichen Praxis an unterschiedlichen Stellen eingesetzt werden können. Über eine Anwendung der Methodik in zwei Fallbeispielen werden das entwickelte Planungs- und Entscheidungsmodul sowie das Mess- und Anpassungsmodul anschließend auf deren Eignung validiert.

Der Autor nimmt im Rahmen der Arbeit eine generalisierte Perspektive ein und hat die Entwicklung einer allgemeinen Methode zum Management von Produktionsanläufen in der Automobilindustrie zum Ziel. Als zentrales Element wird dabei ein Regelkreis verwendet, welcher alle entwickelten Module miteinander verknüpft. Der Ansatz beabsichtigt vor allem die Unterstützung bei Planungs- und Entscheidungsprozessen im Anlauf über entsprechende Bewertungen sowie die Nutzung von Erkenntnissen aus früheren Produktionsanläufen. Eine Anpassungsfähigkeit während eines Anlaufs sowie eine proaktive Fehlervermeidung sind nicht berücksichtigt.

#### 4.2.4 Selbstlernende Ansätze

*Automated production ramp-up through self-learning Systems* nach Ennen et al. (2016)

Ennen et al. (2016) entwickeln ein Konzept zur Realisierung eigenständig lernender cyber-physischer Produktionssysteme (kurz CPPS vgl. Kapitel 2.1.4). Über „Trial and Error-Interaktionen“ mit der umgebenden Welt lernen die Systeme dabei eigenständig Steuerungsstrategien. Am Beispiel einer roboterbasierten Montageanlage zum Scheibeneinbau erlernt das System über eine Sensorauswertung mit der Umgebung die notwendigen motorischen Bewegungsabläufe zur Erfüllung der Montageaufgabe.

Über die beschriebene Ausgestaltung eigenständig lernender roboterbasierter Montageanlagen wird eine Anpassungsfähigkeit der Anlage auf die umgebende Welt realisiert. Das System lernt somit eigenständig Reaktionen auf sich verändernde Bedingungen. Ein weiterer Vorteil besteht in der Reduzierung manueller Programmieraufwände. Im Umfeld der Automobilproduktion ist die Anwendung der „Trial and Error-Interaktionen“ mit dem Umfeld jedoch nicht unproblematisch, da hierdurch Schäden am Fahrzeug, dem Roboter oder

der Umgebung entstehen können. Die Autoren liefern hierfür noch keine inhaltlichen Lösungen und identifizieren diese Problematik als weiteres Untersuchungsfeld. Zudem wird auch der Ansatz einer Fehlervorhersage und einer damit möglichen Fehlervermeidung nicht betrachtet. Das selbstlernende CPPS findet zwar eigenständig Lösungen für Situationen, die im konventionellen Fall zu Stillständen der Anlagentechnik führen würden, jedoch müssten auch in diesem Fall über die „Trial und Error-Interaktionen“ zunächst die zielführenden Parametrierungen gelernt werden. In der betrieblichen Praxis würden relevante Veränderungen der umgebenden Umwelt somit immer in einer, zumindest kurzzeitigen, Verlängerung der notwendigen Montagezeit resultieren, was wiederum im Kontext der hochgetakteten Automobilendmontage (vgl. Kapitel 2.1) zu einer Reduzierung der Tagesproduktion eines Produktionsstandortes führen kann.

#### 4.2.5 Zusammenfassende Betrachtung und Zwischenfazit

Es finden sich noch an weiteren Stellen der wissenschaftlichen Literatur Ansätze zum kennzahlorientierten Anlaufmanagement in der Automobilproduktion, welche jedoch keine grundsätzlich anderen Betrachtungswinkel und Ansätze zu den hier vorgestellten Arbeiten aufweisen (vgl. Gentner 1994; Schmahls 2001; Risse 2003). Dies gilt in gleicher Weise auch für die weiteren hier vorgestellten Kategorien des Anlaufmanagements in der Automobilindustrie. Auf eine vollumfängliche Darstellung all dieser Arbeiten wird aus diesem Grund im Rahmen der vorliegenden Arbeit verzichtet.

Abbildung 22 zeigt eine Bewertung der hier vorgestellten Ansätze hinsichtlich Betrachtungsfokus und der in Kapitel 3 abgeleiteten Anforderungen. Daraus ist ersichtlich, dass in der wissenschaftlichen Literatur bisher keine Ansätze existieren, die sich mit dem Umgang von Störungen im Rahmen einer Anlaufsteuerung in der Automobilindustrie beschäftigen und die abgeleiteten Anforderungen an eine zeitgemäße Systemgestaltung erfüllen. Im folgenden Kapitel 4.3 wird der bestehende Betrachtungswinkel daher um weitere wissenschaftliche Quellen erweitert, die sich aus allgemeiner Sicht oder anderen Industrien als der Automobilindustrie im Speziellen mit dem Umgang von unvorhersehbaren Störungen im Produktionsanlauf befassen. Ein umfassenderer Literaturüberblick zum Umgang mit allgemeinen Störungen im Produktionsanlauf befindet sich in Ulrich (2016).

	Betrachtungsfokus						Anforderungen an eine zeitgemäße Anlaufsteuerung					
	Anlaufstrategie	Anlaufplanung	Anlauforganisation	Anlaufsteuerung	Umgang mit Störungen	Betrachtung automatisierter Montageprozessanlagen	Wahnehmend (nicht vermeidbarer externer Störgrößen)	Entscheidend	Fehlervorhersagend	Fehlervermeidend	Kurzfristig wirksam während des Anlaufs	Selbstlernend und anpassungsfähig
Almgren (1999b)	teilweise erfüllt	teilweise erfüllt										
Fleischer et al. (2003)		vollständig erfüllt		teilweise erfüllt	teilweise erfüllt	teilweise erfüllt			teilweise erfüllt		teilweise erfüllt	
Juering & Milling (2005)	vollständig erfüllt	vollständig erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt					teilweise erfüllt		
Schuh et a. (2005)	vollständig erfüllt	vollständig erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt							
Fitzek (2006)	vollständig erfüllt	vollständig erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt							
Winkler et al. (2007)		teilweise erfüllt		teilweise erfüllt	teilweise erfüllt			teilweise erfüllt	teilweise erfüllt		teilweise erfüllt	
Wolgast und Carlson (2007)	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt						teilweise erfüllt	
Näser und Müller (2008)	teilweise erfüllt	vollständig erfüllt		teilweise erfüllt	teilweise erfüllt						teilweise erfüllt	
Fjällström et al. (2009)			teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt					teilweise erfüllt	
Tücks (2010)		teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt		teilweise erfüllt				teilweise erfüllt	
Juzek (2014)		teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt					teilweise erfüllt	teilweise erfüllt
Bußwolder et al. (2016)		vollständig erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt					teilweise erfüllt	teilweise erfüllt
Ennen et al. (2016)				teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt	teilweise erfüllt			teilweise erfüllt	vollständig erfüllt

Abbildung 22: Übersicht wissenschaftlicher Ansätze zum Anlaufmanagement in der Automobilindustrie.

### 4.3 Umgang mit unvorhersehbaren Störungen im Produktionsanlauf

Basierend auf den Erkenntnissen aus Kapitel 4.2 erfolgt an dieser Stelle eine Betrachtung und Analyse wissenschaftlicher Quellen, die sich im Speziellen mit dem Umgang unvorhersehbarer Störungen im Produktionsanlauf aus allgemeiner Sicht oder anderen Industrien als der Automobilindustrie beschäftigen.

*Turbulenzreaktionsprozesse. Ein Ansatz zur Steigerung der Reaktionsfähigkeit auf Turbulenzen am Beispiel des Produktionshochlaufs* nach Dill (2003; Almgren 1999a)

In der Arbeit von Dill (2003) entwickelt der Autor eine Methode zum verbesserten Umgang mit unerwartet auftretenden Veränderungen, sogenannten Turbulenzen, im Produktionsanlauf. Kernbestandteil der Arbeit ist dabei die Entwicklung und Validierung von Reakti-

onsbausteinen zur Reduzierung der Reaktionszeit über die Gestaltung effizienter Reaktionsprozesse und die Auswahl effektiver Lösungen. Die Reaktionsbausteine sind dabei leicht an die jeweilige Turbulenz anpassbar. Durch eine Anpassung und Anwendung der Bausteine soll dabei die Reaktionsfähigkeit auf Turbulenzen im Produktionsanlauf verbessert werden. In der ersten Phase wird mittels entsprechender Bausteine für Transparenz gesorgt, in der zweiten Phase werden Lösungen entwickelt und bewertet sowie im Anschluss in der dritten Phase umgesetzt.

Die Methodik nach Dill (2003) beschäftigt sich mit unterwartet auftretenden Störungen im Produktionsanlauf. Der Aspekt der Frühwarnung über eine Betrachtung der eigentlichen Störgrößen wird nicht behandelt und abschließend als weiterer Forschungsbedarf identifiziert. Der Aspekt selbstlernender Systeme ist zudem nicht berücksichtigt.

*Entwicklung einer softwareunterstützten Methode für die statistische Prozesssteuerung beim Produktionsanlauf* nach Benz (2004)

Benz entwickelt im Rahmen seiner Arbeit eine speziell auf den Produktionsanlauf ausgerichtete Methode für die statistische Prozesssteuerung am Beispiel einer Gussanlage. Da für den erfolgreichen Einsatz der statistischen Prozesskontrolle auch immer ein gewisses Maß an Prozesswissen notwendig ist, führt der Autor eine Methode für die strukturierte Datenvorbereitung im Produktionsanlauf ein. Auf der Basis dieser Datenvorbereitungsphase werden Produktionsdatensets als Vorlaufdaten für die statistische Prozesskontrolle extrahiert. Aufgrund der speziellen Gegebenheit im Produktionsanlauf leitet Benz weiterhin die Anforderung eines parameterfreien Verfahrens ab und erfüllt diese Anforderung über ein Verfahren der statistischen Prozesssteuerung für die Kerndichteschätzung des Gussprozesses.

Der Ansatz nach Benz (2004) zielt stark auf die Anlaufsteuerung von Gussanlagen oder Anlagen im Bereich der Prozessindustrie ab. Der vorgestellte Ansatz basiert auf der statistischen Prozesskontrolle und eignet sich überall dort, wo mehrdimensionale Prozessfenster zur Vermeidung von Qualitätsproblemen kontinuierlich überwacht und geregelt werden können. Es wird dafür immer ein Mindestmaß an Prozesswissen benötigt, eine konkrete Fehlervorhersage und Fehlervermeidung ohne Modellbildung ist nicht möglich. Auch eine selbstlernende Eigenschaft ist nicht realisiert. Eine Übertragbarkeit des Ansatzes zur effizienten Fehlervermeidung an Montageprozessanlagen ist somit nur sehr eingeschränkt denkbar.

*Continuous Failure Diagnosis for Assembly Systems using Rough Set Approach* nach Mannar und Ceglarek (2004)

Mannar und Ceglarek (2004) stellen in ihrer Arbeit einen Machine-Learning-Ansatz zur Fehlervorhersage in Produktionsanlaufprozessen vor. Der Ansatz betrachtet dabei die Mustererkennung in Sensordaten über das mathematische Konzept unexakter Mengen<sup>1</sup>. Am Beispiel einer automatisierten Montageanlage erfolgt eine Validierung der Methode. Über die Auswertung von 3 Sensoren an den Befestigungspunkten in jeweils 3 Dimensionen zeigen die Autoren, dass der entwickelte Ansatz in der Lage ist, eigenständig Muster in den Sensordaten zu erlernen, welche zu einem Fehler im Montageprozess führen. Die sichere Vorhersagegenauigkeit für Fehler beträgt dabei 85 %.

Die Autoren fokussieren sich auf den Aspekt der Fehler- und Störungsvorhersage. Ein Umgang mit diesen Störungen und einer damit verbundenen Reaktion sowie eine mögliche Fehlervermeidung werden jedoch nicht behandelt. Weiterhin betrachten die Autoren im Rahmen der Validierung lediglich die Genauigkeit der Positionierung als Störgröße für den automatisierten Montageprozess. Weitere unvermeidbare externe Störgrößen in einem realen Produktionsumfeld durch Veränderungen des Umfeldes werden nicht betrachtet.

*Accelerated Ramp-Up of Assembly Systems through Self-learning* nach Oates et al. (2012)

In dieser Arbeit stellen die Autoren einen neuen Ansatz zur Erfassung und Verwendung von Erfahrungswissen während des Anlaufprozesses vor. Die Autoren fokussieren sich dabei auf die Ausgestaltung eines selbstlernenden Wissensmanagementsystems für den Benutzer. Dabei wird der k-nächste-Nachbarn-Algorithmus aus dem Umfeld des maschinellen Lernens angewendet, um aus der Erfahrungsdatenbank einer maschinellen Anlage relevantes Wissen zu extrahieren und zur Verfügung zu stellen. Dieses dient anschließend als Entscheidungshilfe für den Bediener.

Der Ansatz nach Oates et al. (2012) betrachtet somit primär die Ausgestaltung eines selbstlernenden Systems zur Entscheidungsunterstützung für den Bediener im Anlauf. Auf Basis einer existierenden Erfahrungsdatenbank werden Handlungsempfehlungen für die verän-

---

<sup>1</sup> Eine Menge  $X$  heißt exakt falls ihr Rand  $R^\circ$  leer ist, andernfalls heißt  $X$  unexakt.  $R^\circ$  besteht dabei aus allen Objekten, die weder sicher in  $X$  noch sicher in  $\neg X$  liegen (vgl. Pawlak 1982).

derbaren Parameter der maschinellen Anlage gegeben, um darüber eine generelle Systemverbesserung während des Anlaufs zu erreichen. Der Ansatz eignet sich somit nicht um auf sich schnell verändernde Störgrößen im Anlauf eigenständig zu reagieren. Eine Störungsvermeidung ist somit nur bedingt reaktiv möglich. Weiterhin verzichten die Autoren auf eine Validierung des Ansatzes anhand eines realen Anwendungsfalls.

*Concept of a Failures Management Assistance System for the Reaction on Unforeseeable Events during the Ramp-Up* nach Bauer et al. (2014)

Bauer et al. (2014) erarbeiten ein Konzept zum effektiven Fehlermanagement im Produktionsanlauf. Aus Sicht der Autoren sind eine zielgerichtete Kommunikation und eine umfassende Fehlerlösungsdokumentation dabei Schlüsselemente zum Erfolg. Hierfür wird ein cyber-physisches System als Werkzeug entwickelt, welches den Aufwand für die Fehlererfassung und Dokumentation reduziert, auftretende Störungen klassifiziert und entsprechende Workflows zur Problemlösung einleitet. Das System trägt damit zu einer erhöhten Transparenz im Umgang mit Störungen im Anlauf bei. Die Mitarbeiter dienen als Universalsensor zur Problemerkennung und werden vom System in der Entscheidungsfindung bei der Störungsbeseitigung unterstützt.

Der Ansatz nach Bauer et al. (2014) zielt vor allem auf eine Reduzierung der Antwort- und Fehlerbehebungszeit im Produktionsanlauf ab. Das System ist dabei nur sehr eingeschränkt entscheidungsfähig. Im Falle auftretender Probleme dient der Mensch als Sensor und lediglich die Zuordnung des Problems zu Personen mit der wahrscheinlichsten Lösungskompetenz erfolgt eigenständig. Eine Fehlervermeidung und Fehlervorhersage ist nicht berücksichtigt. Eine kontinuierliche Systemverbesserung als selbstlernendes System findet nur eingeschränkt von Anlauf zu Anlauf über eine Erweiterung der Wissensbasis statt.

*Solution Principles for Managing Instabilities in Ramp-up* nach Basse et al. (2014)

Nach Basse et al. (2014) ist der Anlauf eines Produktionssystems einerseits geprägt durch eine hohe Systemkomplexität, da einzelne Entscheidungen im Anlauf weitreichende Folgen für das Gesamtsystem haben können und zum anderen muss mit auftretenden Instabilitäten umgegangen werden, welche die Produktionseffektivität reduzieren können und in einem zeitlichen Verzug bei der Erreichung der geplanten Ausbringungsmenge resultieren.

Zur Beherrschung und Steuerung dieser komplexen und instabilen Anlaufsysteme werden vier Lösungsprinzipien analysiert und eingeführt: Aus Sicht der Autoren sind demnach der Einsatz von „Modellentwicklung“, „geschlossene Regelkreise und Heuristiken“, die „Berücksichtigung eventueller Toleranzen und Selbstoptimierung“ und der „Aufbau von Mustern“ besonders vielversprechend für die Beherrschung von Instabilitäten und Komplexität im Anlauf.

Der Ansatz nach Basse et al. (2014) zielt auf eine Reduzierung der Kernursachen von Instabilitäten im Anlauf ab. Über eine Berücksichtigung der vorgeschlagenen Lösungsprinzipien soll dabei vor allem eine Erleichterung bei der Entscheidungsfindung generiert werden. Der Ansatz berücksichtigt eine grundsätzliche Vermeidung möglicher Ausfälle und Fehler über eine sehr allgemeine Reduzierung von Grundursachen von Instabilitäten im Anlauf. Eine aktive Reaktion hinsichtlich auftretender Störeinflüsse im Sinne einer Anlaufsteuerung sowie der Ansatz selbstlernende Systeme werden nicht berücksichtigt.

#### 4.4 Abgrenzung vom Stand der Forschung und Technik sowie wissenschaftlicher Handlungsbedarf

Nach Ulrich (2016) lässt sich die Literatur über den Umgang mit Störungen im Produktionsanlauf unterteilen in Ansätze, die sich mit der Planung, und diejenigen, die sich mit der Durchführung des Produktionsanlaufs beschäftigen. Ein Großteil behandelt dabei den Planungsaspekt und beabsichtigt über eine entsprechende Planung eventuelle Störungen präventiv zu vermeiden oder zu minimieren. Die Durchführung des Produktionsanlaufs ist hingegen nicht sehr tief erforscht und in der dazu existierenden Literatur wird häufig der Umgang mit Störungen nicht berücksichtigt. (vgl. Ulrich 2016, S. 53)

Dies konnte im Rahmen dieser Arbeit erneut bestätigt werden. Im vorliegenden Kapitel wurden die für diese Dissertation relevanten wissenschaftlichen Arbeiten beschrieben und diskutiert. Aufbauend auf den Vorbetrachtungen und abgeleiteten Anforderungen wurde der Fokus dabei auf bestehende Ansätze zum Anlaufmanagement in der Automobilindustrie und auf die Störungsvermeidung im Produktionsanlauf gelegt. Es konnte daran gezeigt werden, dass die existierenden Ansätze zwar eine generelle Grundlage für eine zeitgemäße

Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage darstellen, jedoch keiner der Ansätze die abgeleiteten Anforderungen gesamthaft erfüllt. Abbildung 23 gibt einen Überblick über die betrachteten wissenschaftlichen Ansätze hinsichtlich Betrachtungsfokus und Erfüllungsgrad der in dieser Arbeit abgeleiteten Anforderungen. Dieser bezieht sich dabei rein auf die Zielsetzung der vorliegenden Arbeit und enthält keine Aussagekraft über die generelle Qualität der betrachteten Ansätze.

	Betrachtungsfokus						Anforderungen an eine zeitgemäße Anlaufsteuerung					
	Anlaufstrategie	Anlaufplanung	Anlauforganisation	Anlaufsteuerung	Umgang mit Störungen	Betrachtung automatisierter Montageprozessanlagen	Wahnehmend (nicht vermeidbarer externer Störgrößen)	Entscheidend	Fehlervorhersagend	Fehlervermeidend	Kurzfristig wirksam während des Anlaufs	Selbstlernend und anpassungsfähig
Almgren (1999b)												
Fleischer et al. (2003)												
Juerging & Milling (2005)												
Schuh et a. (2005)												
Fitzek (2006)												
Winkler et al. (2007)												
Wolgast und Carlson (2007)												
Näser und Müller (2008)												
Fjällström et al. (2009)												
Tücks (2010)												
Juzek (2014)												
Bußwolder et al. (2016)												
Ennen et al. (2016)												
Dill (2003)												
Benz (2004)												
Mannar und Ceglarek (2004)												
Oates et al (2012)												
Bauer et al. (2014)												
Basse et al. (2014)												
Ansatz dieser Arbeit												

Abbildung 23: Übersicht wissenschaftlicher Ansätze zum Anlaufmanagement in der Automobilindustrie und Ansätze zur Störungsvermeidung im Produktionsanlauf weiterer Industrien.

Hierbei ist auffallend, dass keiner der betrachteten Ansätze die Kategorien „fehlvermeidend“ sowie „selbstlernend und anpassungsfähig“ gleichzeitig erfüllt. Fehlvermeidende Systemeigenschaften sind überdies generell kaum berücksichtigt. Juerging und Milling (2005) sowie Benz (2004) sind die einzigen Ansätze in denen die Anforderung einer Fehlvermeidung überhaupt formuliert und berücksichtigt wird. Jedoch findet die Fehlvermeidung hierbei

nicht eigenständig statt. Es erfüllt somit keiner dieser genannten Ansätze neben einer Fehlervermeidung auch die abgeleitete Anforderungskategorie „selbstlernend und anpassungsfähig“.

Zur besseren Veranschaulichung diese Umstandes wurde hierfür in Abbildung 24 die zusätzliche Kategorie „eigenständig und selbstlernend fehlervermeidend“ eingeführt, welche aus den in Kapitel 3.3 formulierten Leitsätzen ableitbar ist und die beiden Kategorien „fehlervermeidend“ sowie „selbstlernend und anpassungsfähig“ miteinander vereint. Hierdurch wird gut ersichtlich, dass keiner der in der Literatur existierenden und hier vorgestellten Ansätze eine eigenständige selbstlernende Fehlervermeidung im Produktionsanlauf berücksichtigt.

	Betrachtungsfokus							Anforderungen an eine zeitgemäße Anlaufsteuerung					
	Anlaufstrategie	Anlaufplanung	Anlauforganisation	Anlaufsteuerung	Umgang mit Störungen	Betrachtung automatisierter Montageprozessen	Wahrnehmung (nicht vermeidbarer externer Störgrößen)	Entscheidend	Fehlervorhersagend	Fehlervermeidend	Kurzfristig wirksam während des Anlaufs	Selbstlernend und anpassungsfähig	Eigenständig und selbstlernend fehlervermeidend
Almgren (1999b)													
Fleischer et al. (2003)													
Juerging & Milling (2005)													
Schuh et a. (2005)													
Fitzek (2006)													
Winkler et al. (2007)													
Wolgast und Carlson (2007)													
Näser und Müller (2008)													
Fjällström et al. (2009)													
Tücks (2010)													
Juzek (2014)													
Bußwolder et al. (2016)													
Ennen et al. (2016)													
Dill (2003)													
Benz (2004)													
Mannar und Ceglarek (2004)													
Oates et al (2012)													
Bauer et al. (2014)													
Basse et al. (2014)													
Ansatz dieser Arbeit													

Abbildung 24: Existierenden wissenschaftliche Lücke und Handlungsbedarf.

Es kann damit festgehalten werden, dass zum aktuellen Zeitpunkt somit kein Konzept existiert wie Fehler, die im Anlauf durch eine natürliche Variation der Umwelteinflüsse hervorgerufen werden, eigenständig von einem Montagesystem vermieden werden können.

Die aus der betrieblichen Praxis identifizierten externen Störeinflüsse (vgl. Kapitel 2.1.3), die aus einer Veränderungen der Umfeldbedingungen resultieren, sind in der wissenschaftlichen Literatur dabei bisher generell kaum betrachtet (vgl. Ulrich 2016, S. 189–192).

Gemäß den in dieser Arbeit ausgeführten Vorbetrachtungen konnte jedoch aufgezeigt werden, dass

- Anläufe geprägt sind von unvorhersehbaren Störeinflüssen (Kapitel 2.2),
- kraftsensitive Montageaufgaben zukünftig verstärkt von Robotern in automatisierten Montageanlagen übernommen werden (Kapitel 2.1),
- im Produktionsanlauf nicht alle Zusammenhänge bekannt und modellierbar sind (Kapitel 2.3),
- die Prozessstabilität einer Anlage von höchster Bedeutung für produzierende Unternehmen heutzutage ist (Kapitel 2.1 & 3.2),
- eine Fehlervermeidung stets gegenüber einer Fehlervorhersage zu bevorzugen ist (Kapitel 3.2).

Eine eigenständige selbstlernende Fehlervermeidung ist somit eine Grundanforderung zur zeitgemäßen Ausgestaltung der Anlaufsteuerung. Im Stand der Forschung existieren hierfür jedoch noch keine Konzepte. Die vorliegende Arbeit widmet sich dem daraus resultierenden Forschungsbedarf. Die an dieser Stelle existierende wissenschaftliche Lücke wird dabei im Rahmen der vorliegenden Arbeit über die Ausarbeitung selbstlernender fehlervermeidender Montagesysteme im Produktionsanlauf gefüllt.

Aus dem Betrachtungswinkel des Standes der Technik lässt sich weiterhin festhalten, dass nach dem Kenntnisstand des Autors dieser Arbeit keiner der beschriebenen wissenschaftlichen Ansätze großflächig in der betrieblichen Praxis eingesetzt wird. Produzierende Unternehmen stehen, wie in den vorgelagerten Kapiteln beschrieben, unter dem Druck ständiger und hochfrequenter Anläufe. Viele der im wissenschaftlichen Stand beschriebenen erarbeiteten Konzepte und Ansätze erfordern eine aktive Befüllung oder eine aktive Maßnahmensteuerung durch Bediener und führen somit in der Anwendung zu recht hohen kapazitiven Aufwänden für die Anlaufsteuerung. In der betrieblichen Praxis haben sich daher stattdessen Konzepte etabliert, welche basierend auf Workshops in möglichst kurzer Zeit eine Risikominimierung etwaiger Anlagenausfälle ermöglichen sollen. Ein Beispiel hierfür ist die Anwendung der besonders gängigen Fehlermöglichkeits- und -einflussanalyse (kurz FMEA). Für eine genaue Erklärung der Wirkweise dieser Methoden sei an dieser

Stelle auf McDermott et al. (1996) verwiesen. Die aktive Steuerung und Behebung auftretender Störungen und Probleme ab dem ersten Anlauftag erfolgt jedoch auch trotz einer durchgeführten FMEA immer rein reaktiv über funktionsübergreifende Regeltermine zum Beginn und Ende einer jeweiligen Produktionsschicht. Diese werden von einer entsprechend definierten Projektleitung angesetzt und zur Aufnahme existierender Probleme verwendet mit anschließender Maßnahmenbestimmung.

Im Gegensatz zu den hier vorgestellten und arbeitsintensiven Methoden der Anlaufsteuerung aus dem Stand der Forschung stellen eigenständige selbstlernend fehlervermeidende Systeme aufgrund ihrer aufwandsarmen Natur eine echte Alternative zu dem beschriebenen Vorgehen der betrieblichen Praxis dar. Die Anwendung intelligenter selbstlernender Produktionsanlagen in einem Stand der Technik steht dabei noch am Anfangspunkt und die betriebliche Praxis somit noch am Beginn der Nutzungsmöglichkeiten dieser Systeme.

Professor Detlef Zühlke vom deutschen Forschungszentrum für künstliche Intelligenz (kurz DFKI) äußerte sich für diesen Umstand beispielhaft in einem Interview im Mai 2017 wie folgt:

„Ich habe noch keine Beispiele für KI (...) in realen Produktionsumgebungen gesehen.“  
(vgl. Spinnarke 2017)

Eigenständig selbstlernende und somit künstlich intelligente Systeme zur Fehlervermeidung können für produzierende Unternehmen in der heutigen Zeit eine hoch effiziente Alternativlösung für die sich zukünftig weiterhin verschärfenden Herausforderungen der Anlaufsteuerung darstellen. Über die Entwicklung und Erprobung eines solchen Ansatzes zur eigenständigen Anpassung roboterbasierter Montageprozessanlagen zur Vermeidung von anlaufbezogenen Montagefehlern können dabei alle in Kapitel 3 abgeleiteten Systemanforderungen zur Ausgestaltung einer effizienten und zeitgemäßen Anlaufsteuerung in einem Ansatz vollständig erfüllt werden. Die entstandene Arbeit vereinigt dafür menschenbezogene Handlungsstrategien zur Optimierung von Anlagentechnik mit aktuellen Erkenntnissen über selbstlernende Systeme.

Es erfolgt dafür im folgenden Kapitel ein Konzeptentwurf zur Ausgestaltung eines selbstlernenden automatisierten Montagesystems zur Fehlervermeidung im Produktionsanlauf.

## 5 Systementwurf eines selbstlernenden automatisierten Montagesystems zur Fehlervermeidung im Produktionsanlauf

Wie im vorgelagerten Kapitel aufgezeigt werden konnte, stellen selbstlernende Systeme zur eigenständigen Fehlervermeidung im Produktionsanlauf nicht nur eine existierende wissenschaftliche Lücke im Stand der Forschung dar, sondern auch eine baldige Notwendigkeit zur effizienten Anlaufbeherrschung in der betrieblichen Praxis produzierender Unternehmen.

Das folgende Kapitel beschreibt den hierfür entwickelten Ansatz zur Ausgestaltung eines selbstlernenden Montagesystems. Zielsetzung der Integration selbstlernender Fähigkeiten ist dabei die Fehlervermeidung im auszuführenden Montageprozess im Produktionsanlauf. Hierfür erfolgt zunächst die Beschreibung der entwickelten Gesamtsystemarchitektur. Die Realisierung selbstlernender Fähigkeiten des Systems erfolgt dabei durch eine Untergliederung in eine selbstlernende Systemkomponente zur Fehlervorhersage und eine selbstlernende Systemkomponente zur Fehlervermeidung. Im weiteren Verlauf des Kapitels werden zunächst eine Reihe geeigneter Algorithmen und Ansätze des maschinellen Lernens für die fehlervorhersagende sowie fehlervermeidende Komponente vorgestellt und hinsichtlich ihrer Eignung diskutiert. Abschließend erfolgt eine Erweiterung der Systemarchitektur durch Ansätze zur Reduzierung hochdimensionaler Merkmalsdatenvektoren.

## 5.1 Grundsystemarchitektur selbstlernender automatisierter Montagesysteme

Das folgende Kapitel beschreibt die entwickelte Systemarchitektur selbstlernender automatisierter Montagesysteme. Die in Kapitel 3 abgeleiteten Systemanforderungen finden hierbei eine vollständige Berücksichtigung. Durch die Unterteilung in eine vorhersagende und eine vermeidende Komponente kann dabei eine menschliche Handlungsstrategie zur Vermeidung von Montagefehlern realisiert werden.

Zielsetzung der entwickelten Systemarchitektur ist die Implementierung selbstlernender Fähigkeiten in ein automatisiertes Montagesystem zur eigenständigen Vorhersage und Vermeidung von Montagefehlern im Produktionsanlauf. Hierfür erfolgt zunächst die Ableitung einer Handlungsstrategie zur Vermeidung eines Montagefehlers. Da Störungsursachen im Anlauf nicht immer vermeidbar sind, leitet sich die Anforderung einer Störungsresistenz an den Systementwurf ab (vgl. Kapitel 2.2.3). Es wird daher eine reaktive Handlungsstrategie auf die Veränderung der externen Einflussvariablen gewählt. Ziel des Systems ist somit nicht die Vermeidung der eigentlichen Störungsursache, sondern die Vermeidung des Störungsergebnisses in Form eines negativen Montageergebnisses. Zur einfachen Nachvollziehbarkeit ist die Handlungsstrategie dem menschlichen Handeln nachempfunden und es erfolgt nur eine Abweichung von der gegebenen Montagestrategie für den wahrscheinlichen Fall eines auftretenden Fehlers im Montageergebnis. Zur Realisierung der Handlungsstrategie wurde die Systemarchitektur in zwei selbstlernende Teilkomponenten A und B untergliedert (vgl. Abbildung 25). Für den Fall einer Fehlervorhersage durch die selbstlernende Teilkomponente A leitet Teilkomponente B eine proaktive Gegenmaßnahme ein. Teilkomponente B erlernt dabei über die Zeit, welche der zur Verfügung stehenden proaktiven Gegenmaßnahmen in welchem Fall zum gewünschten Montageerfolg führt.

Die in Kapitel 3 abgeleiteten Systemanforderungen sind in der entwickelten Systemarchitektur berücksichtigt und realisiert. Abbildung 25 zeigt eine Gesamtübersicht der entwickelten Systemarchitektur.

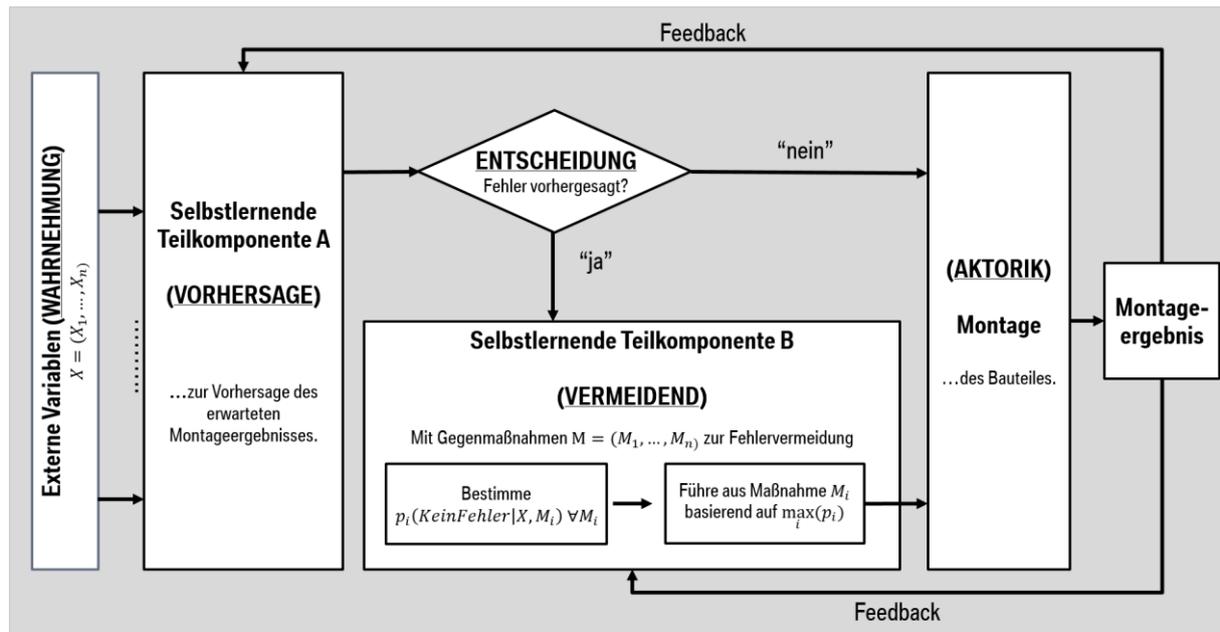


Abbildung 25: Gesamtübersicht Systemarchitektur selbstlernender automatisierter Montagesysteme.

Über die Datenaufnahme und unter Verwendung entsprechender Sensorik erhält das System eine Wahrnehmung über die aktuelle Situation und Veränderungen in den externen Variablen. In einer ersten selbstlernenden Komponente erfolgen zunächst eigenständig Rückschlüsse zwischen dem jeweiligen Merkmalsvektor der externen Variablen eines speziellen Montagevorgangs und dem darunter erreichten Montageergebnis. Anhand dieser Rückschlüsse erlernt die Teilkomponente A Muster in den Eingangsdaten, welche einen negativen Einfluss auf das Montageergebnis bewirken. Aufbauend auf diesen Erkenntnissen erfolgt für jeden individuell auszuführenden Montagevorgang eine Fehlervorhersage durch Teilkomponente A. Basierend auf dieser Vorhersage trifft das System anschließend nur für den Fall einer Fehlervorhersage die Entscheidung, von der gegebenen Montagestrategie abzuweichen. Ist die Fehlervorhersage der Teilkomponente hingegen negativ, wird also kein Fehler im Montageergebnis vorhergesagt, so erfolgt der automatisierte Verbau basierend auf der gegebenen Montagestrategie. Im Fall einer Systementscheidung zur Abweichung von der gegebenen Montagestrategie erfolgt die Aktivierung der zweiten selbstlernenden Teilkomponente B. Diese bestimmt anhand eines fest vorgegebenen Sets an möglichen proaktiven Gegenmaßnahmen, welche der Gegenmaßnahmen unter den existierenden Bedingungen mit der höchsten Wahrscheinlichkeit zum Erfolg führt und leitet diese für den auszuführenden Montagevorgang ein. Hierbei erlernt Teilkomponente B aus vergangenen Entscheidungen somit die jeweils beste Gegenmaßnahme für den gegebenen Merkmalsvektor.

Über die regelmäßige Rückkopplung der realen Montageergebnisse zu beiden selbstlernenden Teilkomponenten erfolgt eine eigenständige Verbesserung in der Fehlervorhersage und Fehlervermeidung des Gesamtsystems über maschinelles Lernen innerhalb der Anlaufphase.

## 5.2 Geeignete Algorithmen des maschinellen Lernens für die Ausgestaltung der selbstlernenden Teilkomponenten

In Kapitel 2.3 dieser Arbeit wurde ein Einblick in die grundsätzlichen Möglichkeiten zur Fehlervorhersage und Fehlervermeidung in der Produktionstechnik gegeben. Hierbei erfolgte die Unterscheidung in modellbasierte und wissensbasierte Ansätze. Wissensbasierte Ansätze bieten vor allem dann Vorteile, wenn die mathematische Modellierung eines physikalischen Prozesses sehr schwierig ist. Im Produktionsanlauf neuartiger automatisierter Montagesysteme scheint dies aufgrund hoher existierender Unsicherheiten häufig der Fall zu sein (vgl. Kapitel 1.1). Besonders datengetriebene maschinelle Lernmodelle wie beispielsweise neuronale Netze scheinen für die Erreichung einer zunehmenden Störungsrobustheit im Anlauffall vielversprechend, da prozessbedingte Zusammenhänge darüber oft aus den zur Verfügung stehenden Prozessdatensets extrahiert werden können (vgl. Chiang et al. 2001, S. 10). In diesem Kapitel erfolgt die weitere Detaillierung einiger möglicher datengetriebener maschineller Lernverfahren und den damit verbundenen Algorithmen zur Ausgestaltung der selbstlernenden Komponenten der in Kapitel 5.1 beschriebenen Systemarchitektur. Der Fokus liegt hierbei auf der möglichen Eignung existierender Algorithmen und Ansätze für die beschriebenen selbstlernenden Komponenten. Dabei wird in den Fall der Fehlervorhersage (Komponente A) sowie in den Fall der Fehlervermeidung (Komponente B) unterschieden.

### 5.2.1 Selbstlernende Komponente zur Fehlervorhersage

Aufgrund der naheliegenden Ähnlichkeit zwischen Fehlervorhersage und Fehlererkennung wird die Fehlervorhersage in der Literatur häufig ebenfalls als ein Klassifizierungsproblem behandelt. Die Aufgabe der Fehlervorhersage besteht darin abzuschätzen, mit welcher Wahrscheinlichkeit und zu welchem Zeitpunkt ein Fehler schlussendlich eintreten wird. (vgl. Yan 2014, S. 2)

Weiterhin ist das Auftreten eines Fehlers im Montageergebnis immer eindeutig. Der Montagevorgang findet somit unter Erfüllung der vorgegebenen Qualitätsanforderungen erfolgreich statt oder nicht. Am Beispiel einer automatisierten Montageanlage ist somit nach jedem Montagevorgang eine eindeutige binäre Klassifizierung in „in Ordnung“ (kurz i. O.) und „nicht in Ordnung“ (kurz n. i. O.) möglich. Es handelt sich hierbei somit um ein binäres Klassifizierungsproblem mit eindeutig gekennzeichneten Daten, somit erscheinen datengetriebene Lernmodelle des Supervised Learning (vgl. Kapitel 2.3.4) als geeignet. Innerhalb dieser Gruppe stehen wiederum unterschiedliche maschinelle Lernalgorithmen zur Auswahl.

Zwei besonders erfolgreiche und häufig verwendete Arten von Algorithmen dieser Form stellen Support Vector Machines (kurz SVM) und Artificial Neural Networks (kurz ANN), im besonderen Multi-Layer-Perzeptrons (kurz MLP) dar (vgl. Tong und Koller 2001, S. 45; Hsu et al. 2003, S. 1; Kotsiantis et al. 2007, S. 251; Ben-Hur und Weston 2010, S. 223; Schmidhuber 2015, S. 85–117). Diese werden im Folgenden kurz erläutert.

SVMs stellen die am häufigsten verwendete Form der sogenannten Kernel-Methode dar (vgl. Aoki-Kinoshita 2008, S. 4). Der sogenannte „Kernel-Trick“ ermöglicht es dieser Gruppe dabei auch auf nicht lineare Klassifikationsprobleme angewendet zu werden. Im Detail handelt es sich bei SVMs um sogenannte „Maximum Separation Margin Classifiers“ (vgl. Villmann et al. 2017, S. 69).

Das Wirkprinzip eines solchen Klassifikators besteht in einer Maximierung des Trennungsrandes zwischen zwei oder mehreren Klassen, welcher über die Breite einer separierenden Hyperebene beschrieben ist. Häufig findet die Soft-Margin-SVM Anwendung, deren Entscheidungsmodell dabei gewöhnlich über ein Minimierungsproblem folgender Form definiert ist:

$$\min \left( C \sum_{n=1}^N \varepsilon_n + \frac{1}{2} \|w\|_2^2 \right) \text{ unter der Bedingung } y_i((w, x_i) + b) \geq 1 - \varepsilon_n \quad (5.1)$$

Bei diesem Fall der SVM sind somit über die Einführung einer positiven Schlupfvariablen  $\varepsilon$  grundsätzlich Verletzungen der Nebenbedingungen ermöglicht, jedoch wird jede Verletzung bestraft und die Summe dieser Verletzungen über die Zielfunktion minimiert. Über die Konstante  $C$  wird das Verhältnis zwischen Maximierung des Trennungsrandes und der

Bestrafung nicht korrekter Klassifizierungen beeinflusst. (vgl. Steinwart und Christmann 2008, S. 12–19)

Für weiterführende Details zur Funktionsweise von Support Vector Machines sei an dieser Stelle auf Hearst et al. (1998) und Steinwart und Christmann (2008) verwiesen.

Mult-Layer-Perzeptron-Netzwerke (kurz MLP) repräsentieren einen speziellen Fall der in Kapitel 2.3.3 vorgestellten künstlichen neuronalen Netze und sind in ihrer Anwendung seit vielen Jahren die am weitesten verbreitete Form künstlich neuronaler Netze (vgl. Zhang 2000, S. 451). Im Speziellen handelt es sich bei MLPs um Feed-Forward-Netze, in denen der Signalaustausch nur zwischen Neuronen einer Schicht mit Neuronen der nächstgelegenen Schicht entlang der Hauptrichtung Eingangs- zur Ausgangsschicht möglich ist (vgl. Kotsiantis et al. 2007, S. 255; Goodfellow et al. 2016, S. 164). Dabei ist jedes Neuron einer Schicht mit allen Neuronen der nächst höheren Schicht verbunden. Folglich wird in diesem Kontext auch von „Fully Connected Neural Networks“ gesprochen (vgl. Gardner und Dorling 1998).

Die Grundarchitektur von MLPs besteht dabei aus mindestens drei Schichten. Einer Eingangsschicht, einer Ausgangsschicht und mindestens einer verborgenen Schicht. (vgl. Basheer und Hajmeer 2000, S. 6)

Die Perzeptron-Lernregel geht auf Rosenblatt (1960) zurück und beschreibt die Funktionsweise der sich im Netz befindlichen Neuronen. Hierbei ist jedes Neuron, mit Ausnahme der Neuronen in der Eingabeschicht, über gewichtete Verbindungen mit den Neuronen der jeweils höheren Schicht verbunden. Jedes Neuron benutzt dabei zur Signalverarbeitung eine Aktivierungsfunktion. Über einen Vergleich des Ergebnisses der Ausgangsschicht mit dem korrekten Ergebniswert wird im Fehlerfall über die Berechnung und Rückführung eines Fehlerwertes (engl. Backpropagation) eine Anpassung der Gewichte des Netzes bewirkt (vgl. Widrow und Lehr 1990, S. 1424–1425). Ziel des MLP ist somit die Minimierung des Fehlers der Ausgangsschicht  $E$ .

$$E = \frac{1}{2} \sum_{\text{Ausgaben } k} (V_k - \widehat{V}_k)^2 \quad (5.2)$$

Hierbei entspricht  $E$  der Differenz zwischen dem zu erzielendem Output und dem realen Output der Ausgangsschicht. Die Anpassung der Gewichte des Netzwerks erfolgt gemäß:

$$\Delta T_{ab} = -\mu \frac{\partial E}{\partial T_{ab}} \quad (5.3)$$

Hierbei entspricht  $\mu$  der Lernrate und  $T_{ab}$  dem Gewicht des a-ten Neurons einer Schicht mit dem b-ten Neuron in der Folgeschicht. (vgl. Murray 1995, S. 8–13)

MLPs eignen sich zur Lösung auch nicht linearer Klassifikationsprobleme. Für einen tieferen Einblick in die Funktionsweise von MLPs sei an dieser Stelle verwiesen auf Riedmiller (1994), Murray (1995) und Goodfellow et al. (2016).

Neben den bereits vorgestellten Ansätzen SVM und MLP existiert in Form der sogenannten Learning Vector Quantization (kurz LVQ) die Möglichkeit prototypenbasierter Klassifikation und damit eine weitere interessante Kategorie zur Lösung des vorliegenden Klassifizierungsproblems aus dem Umfeld des Supervised Machine Learning.

Der Klassifikator wird dabei über eine Menge gekennzeichnete Prototypen parametrisiert, welche die Klassen der Eingangsdaten repräsentieren, zusammen mit einem Entfernungsmaß. Die Klassifizierung unbekannter Daten erfolgt dabei anhand des Entfernungsmaßes über die Zuordnung zu dem nächstgelegenen Prototypen. Neben dem ursprünglich von Kohonen (1995) vorgestellten ersten Algorithmus LVQ1 wurden in den letzten Jahren zahlreiche weitere Varianten der Learning Vector Quantization entwickelt und vorgestellt. (vgl. Schneider 2010, S. 5–6)

Neben LVQ1, in dem iterativ eine Verschiebung der existierenden Prototypen über die Trainingsdatenmenge erfolgt, existiert mit Generalized Learning Vector Quantization (kurz GLVQ) ein Algorithmus, welcher das Konzept LVQ dabei über die Minimierung der Kostenfunktion des Fehlers  $K$  mittels einer Transferfunktion  $f$  und einer Klassifizierungsfunktion  $\mu_d^w$  erweitert. GLVQ verfolgt dabei einen heuristischen Ansatz und findet häufig Anwendung, da es im Allgemeinen über gute Generalisierungsfähigkeiten verfügt und ein Konvergieren sichergestellt ist (vgl. Schneider 2010, S. 10). Die Kostenfunktion ist definiert über:

$$K = \frac{1}{2} \sum_{n=1}^N f(\mu_d^w) \quad \text{mit} \quad \mu_d^w(v) = \frac{d^+(v) - d^-(v)}{d^+(v) + d^-(v)} \quad (5.4)$$

$d^+$  und  $d^-$  beschreiben dabei den Abstand des Input  $v$  zum nächstgelegenen Prototypen innerhalb der Klasse  $w^+$ , also dem nächstgelegenen korrekten Prototypen bzw.  $w^-$ , dem nächstgelegenen Prototypen anderer Klassen, also dem nächstgelegenen inkorrekten Prototypen. Häufig wird dabei die sigmoid-Funktion als Transferfunktion und die euklidische Distanz als Maß für die Distanz verwendet.

Für einen detaillierten Einblick in die Historie und Funktionsweise von LVQs sei an dieser Stelle auf Kohonen (2001 Seite 245-261) sowie für einen allgemeinen Überblick unterschiedlicher LVQ Varianten auf Schneider (2010) verwiesen.

Die identifizierten und beschriebenen drei Grundtypen maschineller Lernalgorithmen des Supervised Machine Learning bieten ihrerseits individuelle Vor- und Nachteile und eignen sich je nach Rahmenbedingungen des Klassifizierungsproblems unterschiedlich gut.

SVMs bieten aufgrund ihrer hohen Generalisierungsfähigkeit häufig dann Vorteile, wenn die zur Verfügung stehende Datenmenge gering ist. Ein weiterer Vorteil von SVMs liegt in einer hohen Robustheit gegenüber Modellverletzungen und vereinzelt Ausreißern innerhalb der Datenmuster. Weiterhin sind SVMs durch eine hohe rechnerische Effizienz gekennzeichnet und die Anforderung an die zur Verfügung stehenden Berechnungskapazitäten ist somit eher niedrig. (vgl. Steinwart und Christmann 2008, S. 12–19)

MLPs hingegen bieten häufig Vorteile beim Umgang mit einer hohen Datenkomplexität und zeigen in vielen Fällen eine hohe Robustheit gegenüber Rauschen in der zur Verfügung stehenden Datenmenge aufgrund der hohen Verteilung der Prozessinformationen im Netzwerk. Weitere Vorteile sind die einfache Skalierbarkeit und die grundsätzliche Fähigkeit nicht-linear separierbare Datenmengen bei entsprechender Datenquantität und -qualität mit einer sehr hohen Genauigkeit zu klassifizieren. (vgl. Svozil et al. 1997, S. 49)

LVQs zeichnen sich durch die einfache Übertragbarkeit auf mehrklassige Klassifikationsprobleme aus, dies ist häufig ohne Anpassung des Lernalgorithmus und der Entscheidungsregel möglich. LVQs bieten weitere Vorteile beim Umgang mit unvollständigen Datensets, da der fehlende Teil der Informationen für den Vergleich zwischen den Prototypen einfach ausgeklammert werden kann. Im Vergleich zu den beschriebenen SVMs und MLPs liegt eine weitere Besonderheit von LVQs in der einfachen Nachvollziehbarkeit. Die jeweiligen Prototypen repräsentieren die jeweils klassenspezifischen Datencharakteristika und ermöglichen somit Einblicke in die identifizierten Datenmuster. (vgl. Schneider 2010, S. 5)

### **Zwischenfazit & These**

Es stellt sich somit die Frage, welches der beschriebenen Lernverfahren für den in dieser Arbeit beschriebenen Ansatz der Fehlervorhersage am besten geeignet erscheint. Im gewählten Anwendungsfall der Automobilendmontage sind heutzutage Tagesproduktionen von 1000 Fahrzeugen (vgl. Kleinhenz et al. 2006, S. 15) üblich. Selbst bei nur einmaliger Ausführung des Montageprozesses pro Fahrzeug entspricht dies einer Datenmenge von 1000 Testdaten pro Anlauftag und dementsprechend ist bereits nach wenigen Tagen unter Umständen eine ausreichende Datenquantität auch im Anlauf vorhanden. Weiterhin scheint eine gewünschte Datenvollständigkeit über die Implementierung entsprechender Sensorkonzepte innerhalb der Gesamtanlage gut darstellbar. Die Bereitstellung ausreichender Berechnungskapazitäten lokal oder über entsprechende Serverstrukturen ist in der heute bereits hoch technologisierten Automobilproduktion ebenfalls realistisch. Viele der beschriebenen individuellen Vorteile von SVMs scheinen im gewählten Anwendungsfall somit weniger bedeutend.

Das besondere Differenzierungsmerkmal einer möglichen Nachvollziehbarkeit prototypenbasierter Klassifikation über LVQs ist nur dann wirklich von Vorteil, wenn der zu betrachtende Merkmalsvektor eine überschaubare Anzahl externer Variablen beinhaltet. Bei der in vielen Montageprozessen notwendigen Verarbeitung von über 100 000 Datenpunkten ist eine Nachvollziehbarkeit auch über die Anwendung von LVQs nicht mehr möglich und der spezifische Vorteil erscheint im Anwendungsfall dieser Arbeit also weniger bedeutend. Weiterhin ist nach Hammer und Villmann (2002) für die erfolgreiche Anwendung von LVQs eine möglichst geringe Dimensionalität der Eingangsdaten erforderlich. Da im konkreten Fall einer binären Klassifikation zudem auch nur eine Unterscheidung zwischen zwei Prototypen möglich ist, kann davon ausgegangen werden, dass die Lernfähigkeit von LVQs somit im Falle der hohen Datenkomplexität automatisierter Montagevorgänge in der Automobilproduktion stark beschränkt ist und LVQs sich somit als weniger geeignet herausstellen werden.

Beim Vergleich zwischen SVMs und MLPs kommen zum einen die spezifischen Vorteile von SVMs nicht zum Tragen und weiterhin kann, aufgrund möglicher Merkmalsvektoren mit weit über 100 000 Dimensionen pro Montageprozess (vgl. Kapitel 6.3), die mögliche Datenkomplexität als hoch eingestuft werden. Hieraus leitet sich die naheliegende Annahme ab, dass im gewählten Anwendungsumfeld MLPs mit einer hohen Wahrscheinlich-

keit die besten Vorhersageergebnisse liefern werden und dementsprechend für die Ausgestaltung der selbstlernenden Teilkomponente A am besten geeignet erscheinen (vgl. Kapitel 5.1).

Zur Bestätigung dieser Annahme erfolgt im Rahmen des nachfolgenden Kapitels 6 ein Vergleich der identifizierten maschinellen Lernverfahren anhand eines Realbeispiels und damit eine Beweisführung zur Bestätigung der hier aufgestellten These.

### 5.2.2 Selbstlernende Komponente zur Fehlervermeidung

Für die Ausgestaltung der zweiten selbstlernenden Teilkomponente B (vgl. Kapitel 5.1) liegt ein fundamentaler Unterschied zur Teilkomponente A (vgl. Kapitel 5.2.1) in der Einfachheit, mit welcher eine dafür benötigte vollständige Datenmenge erzeugt werden kann. Im Fall der Teilkomponente A entsteht über den kontinuierlichen Betrieb der automatisierten Montageprozessanlage und unter Aufnahme der beschriebenen externen Variablen über die Anlaufzeit eine klar gekennzeichnete und für diese Form der Klassifizierung vollständige Datenmenge. Aus dieser können durch Supervised Learning-Algorithmen entsprechende Zusammenhänge zwischen Eingangs- und Ausgangsgrößen abgeleitet werden. Im Falle der Fehlervermeidung ist hingegen für den erwarteten Fehlerfall jeweils eine Gegenmaßnahme aus einem endlichen Set definierter möglicher Maßnahmen auszuwählen. Jedoch existiert anfänglich kein Wissen über die jeweilige Wirksamkeit einer Maßnahme auf den durch einen erfassten Merkmalsvektor definierten bevorstehenden individuellen Montageprozess. Daher ist es naheliegend, die Auswahl der Gegenmaßnahmen zunächst mittels einer gleichverteilten Wahrscheinlichkeitsfunktion auszuführen. Aufgrund des Nichtvorhandenseins entsprechender Informationen über die Wirksamkeit der Gegenmaßnahmen wird für einen jeden Montagevorgang, in dem ein Fehlerfall vorhergesagt ist, jede der möglichen Maßnahmen initial als gleich wirksam angenommen.

Aufbauend auf diesen initialen Annahmen entsteht erneut eine Datenmenge, in welcher die Ausgangsgrößen, basierend auf einem Inputvektor der externen Variablen und einer bei positiver Fehlervorhersage gewählten Maßnahme, über die binäre Unterscheidung in i. O. oder n. i. O gekennzeichnet werden können. Zur Ausgestaltung der selbstlernenden Komponente zur Fehlervermeidung bietet sich die Anwendung von Algorithmen, die einen Zusammenhang zwischen Eingangs- und Ausgangsgrößen ableiten. Mit Bezug auf Kapitel

2.3.4 ist somit die Anwendung von Supervised Learning oder Reinforcement Learning ziel-führend.

Für die Anwendung von Supervised Learning spricht die damit erreichbare Durchgängig-keit im Gesamtmodell. Durch die Anwendung desselben Algorithmus, welcher sich für die Ausgestaltung der fehlervorhersagenden Komponenten als erfolgreich erwiesen hat, kann ein Teil des bereits programmierten und empirisch optimierten Lernmodells wiederverwendet werden und damit von Synergien zwischen beiden selbstlernenden Teilkomponen-ten profitiert werden. Ein weiteres Argument für eine möglichst hohe Durchgängigkeit in der Systemarchitektur liegt in der damit erleichterten Beherrschbarkeit für den Anlagenbediener und Instandhalter. Auf der anderen Seite ist über die Anwendung des Supervised Learning nur ein sehr eingeschränkter kontinuierlicher Lernprozess möglich. Unter An-nahme der beschriebenen gleichverteilten Anwendung der Gegenmaßnahmen muss zu-nächst eine ausreichend große und klar gekennzeichnete Datenmenge erzeugt werden. Da Gegenmaßnahmen jedoch nur im Sonderfall eines vorhergesagten Fehlers Anwendung fin-den, ist besonders im Falle eines großen Sets möglicher Gegenmaßnahmen damit zunächst eine Datenaufnahme über einen längeren Zeitraum der Anlaufphase notwendig. Innerhalb dieses Zeitraums ist dabei mit keiner realen Verbesserung der Anlagenleistung zu rechnen, da die Auswahl einer tatsächlich wirksamen Gegenmaßnahme für den individuellen Mon-tageprozess daher rein zufällig stattfindet. Erst nach der Erzeugung einer ersten ausreichend großen und markierten Datenmenge kann ein Lernen des Systems hinsichtlich der Fehler-vermeidung stattfinden. Eine von hier an weiterhin kontinuierliche Verbesserung der Feh-lervermeidung kann nur über die erneute Aufnahme einer weiteren Datenmenge erfolgen, auf deren Basis ein erneutes Lernen und damit ein Update des Lernmodells stattfindet. Das erneute Lernen kann also nur nach der jeweiligen Bildung einer weiteren ausreichend gro-ßen Datenmenge erfolgen. Wie groß diese Datenmenge ist muss dabei vom Bediener be-stimmt werden.

Die Grundidee von Reinforcement Learning (vgl. Kapitel 2.3.4) ist die Maximierung des Erwartungswertes zukünftiger Belohnung über eine Veränderung der hinterlegten Hand-lungsfunktion (vgl. Ennen et al. 2016, S. 59). Für die Anwendung von Reinforcement Lear-ning spricht die Möglichkeit, dass durch die Anwendung dieser Form des maschinellen Ler-nens kontinuierlichere Lernprozesse mit flüssigen Performanceverbesserungen ausgestaltet werden können (vgl. Doya 2000, S. 221). Ein weiterer Vorteil in der Anwendung von Rein-

forcement Learning liegt darin, dass eine unterschiedlich positive Bewertung jeder zur Verfügung stehenden Gegenmaßnahme relativ einfach möglich ist. In der betrieblichen Praxis sind Zustände denkbar, in denen über mehrere individuelle Gegenmaßnahmen nach einer Fehlervorhersage ein Fehler im Montageergebnis verhindert werden kann. Gleichzeitig liegt es nahe, dass dabei nicht alle dieser Maßnahmen aus Gesamtsystemsicht gleich präferiert sind. Am Beispiel einer Gegenmaßnahme, die bei kontinuierlicher Anwendung den Systemverschleiß erhöht, ist nachvollziehbar, dass nur eine moderate Anwendung dieser Gegenmaßnahme aus Gesamtsystemsicht gewünscht ist; die Gegenmaßnahme also nur dann Anwendung finden sollte, falls keine weitere zur Verfügung stehende Gegenmaßnahme ebenfalls eine Fehlervermeidung im vorliegenden Montageprozess ermöglicht, dabei ihrerseits aber zu keinem erhöhten Systemverschleiß führt. Eine Herausforderung von Reinforcement Learning liegt jedoch in einem hohen Bedarf hinsichtlich der verfügbaren Datenquantität, da zunächst für jeden auftretenden Systemzustand gelernt werden muss, welche Maßnahmen in diesem Systemzustand zu welchem Erwartungswert zukünftiger Belohnung führen. Klassische Reinforcement Learning-Ansätze eignen sich daher bei einer geringen Menge möglicher Systemzustände oder wenn eine hohe Datenquantität mittels simulativ erzeugbarer Daten erreicht werden kann.

Der in Mnih et al. (2013) vorgestellte Ansatz „Deep Q-Learning“ ermöglicht es, über Reinforcement Learning einen kontinuierlichen Lernprozess zu gestalten und dabei gleichzeitig eine relativ hohe Durchgängigkeit in der entwickelten Systemarchitektur zwischen beiden selbstlernenden Teilkomponenten zu erreichen und somit folglich beiden beschriebenen gewünschten Zielsetzungen für die Ausgestaltung der fehlervermeidenden Teilkomponente zu entsprechen. In Kapitel 5.2.1 dieser Arbeit konnte die Anwendung neuronaler Netze argumentativ als beste der betrachteten Lösungen für die Ausgestaltung der fehlervorhersagenden Systemkomponenten identifiziert werden. Deep Q-Learning verbindet ein neuronales Netz mit einem Reinforcement Learning-Algorithmus. Das verwendete neuronale Netz wird dabei als Funktionsapproximator einer Wertefunktion zur Bestimmung der zukünftig erwarteten Belohnung eingesetzt. Der damit verfolgte Reinforcement Learning-Ansatz ist somit in der Lage, auch für bis dahin unbekannte Systemzustände den Erwartungswert zukünftiger Belohnung für die zur Verfügung stehenden Maßnahmen mit relativ hoher Genauigkeit abzuschätzen (vgl. Mnih et al. 2013, S. 7–8). Hiermit wird weiterhin das erwähnte Problem einer erforderlichen hohen Datenquantität konventioneller Reinforcement Learning-Ansätze im Falle einer großen Menge möglicher Systemzustände gelöst.

Über die Implementierung eines  $\epsilon$ -Greedy Ansatzes erfolgt mit einer Wahrscheinlichkeit von  $\epsilon$  die Auswahl einer zufälligen Maßnahme, was wiederum zu einer Reduzierung der Gefahr einer instabilen Lernfähigkeit neuronaler Netze bedingt durch lokale Minima führt.

Aufgrund der vorliegenden Kombination der beschriebenen Vorteile über Deep Q-Learning kann dieses Verfahren an dieser Stelle für die Ausgestaltung der fehlervermeidenden Systemkomponente als sehr gut geeignet identifiziert werden. Im anschließenden Kapitel 6 dieser Arbeit erfolgt daher die Auswahl und prototypische Umsetzung des beschriebenen Deep Q-Learning-Ansatzes für die Fehlervermeidung. Damit erfolgt zum einen die Bestätigung der besonderen Eignung dieses Ansatzes für die Systemgestaltung und die vollständige Entwicklung eines fehlervermeidenden Gesamtsystems.

Zur erfolgreichen Anwendung von Deep Q-Learning zur selbstlernenden Fehlervermeidung im Kontext der vorliegenden Arbeit muss die Auswahl einer entsprechend erfolgreichen Gegenmaßnahme belohnt und die Auswahl und Anwendung einer nicht erfolgreichen Gegenmaßnahme bestraft werden. Es ist dabei nachvollziehbar, dass ein n. i. O. Verbau unter Anwendung einer Gegenmaßnahme dabei ein schlechteres Szenario darstellt wie ein n. i. O. Montageergebnis ohne Gegenmaßnahme. Weiterhin ist es nachvollziehbar, dass ein i. O. Verbau ohne Gegenmaßnahme ein noch besseres Szenario darstellt wie ein i. O. mit Gegenmaßnahme. Es ergibt sich daraus für die Konzeptionierung einer selbstlernenden Fehlervermeidung somit folgende Rangordnung möglicher Montageergebnisse:

1. Montageergebnis ohne Gegenmaßnahme i. O.
2. Montageergebnis unter Gegenmaßnahme i. O.
3. Montageergebnis n. i. O.
4. Montageergebnis n. i. O. unter Gegenmaßnahme

Für den Fall mehrerer zur Verfügung stehender Gegenmaßnahmen muss zusätzlich eine Rangfolge der unterschiedlichen Gegenmaßnahmen zueinander erfolgen.

Eine erfolgreiche Realisierung selbstlernender fehlervermeidender Systemeigenschaften von Montagesystemen im Produktionsanlauf basiert dabei immer auf einem möglichst erfolgreichen Lernprozess. Um dies zu gewährleisten muss über eine entsprechende Konzeptionierung der Belohnung- und Bestrafungsfunktion der Algorithmus inzentiviert werden die Gegenmaßnahme einzuleiten die einen Fehler mit dem geringstmöglichen Aufwand vermeidet.

Weiterhin gilt es richtig abzuwägen zwischen der Wahrscheinlichkeit einer erfolgreichen Fehlervermeidung durch verschiedene zur Verfügung stehende Gegenmaßnahmen und den damit einhergehenden Nachteilen sowie dem etwaigen Verzicht auf eine Fehlerkorrektur. All dies erfolgt über die Aufstellung der Belohnungsfunktion und wurde im vorliegenden Ansatz entsprechend berücksichtigt. Um die beschriebene Zielsetzung zu erreichen, ergibt sich die Belohnung im erarbeiteten Ansatz dieser Arbeit für den Fall eines i. O. Montageergebnisses als ein positives Vielfaches der Anzahl der zur Verfügung stehenden Maßnahmen und gleich Null für den n. i. O. -Fall, unter der Berücksichtigung eines Abzuges für die Anwendung der Gegenmaßnahme (vgl. Formel (5.5)).

$$\begin{aligned}
 \text{Belohnung} &= (1 - \text{Resultat}) * \frac{100}{3} * \# \text{Anzahl Maßnahmen} - X_m * 20 \\
 &\quad \text{mit} \\
 \text{Resultat} &= 1 \text{ für n. i. O. Montageergebnis} \\
 \text{Resultat} &= 0 \text{ für i. O. Montageergebnis} \\
 \text{und } X_m &= m \text{ für alle Massnahme } m = 1, \dots, n
 \end{aligned}
 \tag{5.5}$$

Die Maßnahmen müssen dabei so angeordnet sein, dass die Anwendung der Maßnahme M(1) die geringsten Nachteile aus der Menge aller Maßnahmen verursacht und für die Rangordnung folgende weitere Logik gilt:

Nachteile der Maßnahme M(n) größer Nachteile der Maßnahme M(n-1)

sowie

Nachteile der Maßnahme M(n) kleiner Nachteile der Maßnahme M(n+1).

Mit einer Wahrscheinlichkeit von  $\varepsilon$  erfolgt weiterhin die Auswahl einer zufälligen Maßnahme und die anschließende Reduzierung von  $\varepsilon$  um einen konstanten Faktor bis ein minimaler Wert gleich 0,01 erreicht ist (vgl. Abbildung 26).

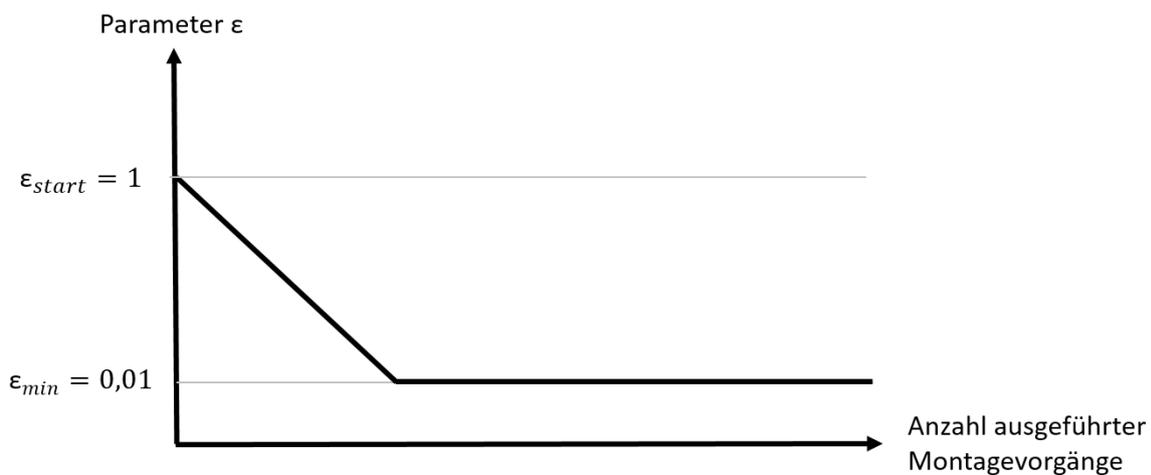


Abbildung 26: Veränderung des  $\epsilon$ -Greedy-Parameters im konzeptionierten Ansatz.

### 5.3 Reduzierung hochdimensionaler Merkmalsdatenvektoren über Expertenwissen

Gemäß Kapitel 2.3.4 dieser Arbeit liegt eine Grundvoraussetzung für den Erfolg datengetriebener Ansätze in einer hohen Qualität und Quantität der zur Verfügung stehenden Datenmenge. Durch eine Reduzierung des Merkmalsdatenvektors besteht darüber hinaus grundlegend die Möglichkeit, die Genauigkeit und die Geschwindigkeit maschineller Lernverfahren auf einer bestehenden Datengrundlage zu steigern, indem der Merkmalsdatenvektor um einen Teil der nicht notwendigen Informationen reduziert wird. Neben einer Anzahl etablierter Methoden wie ICA, PCA und CNN wird im folgenden Kapitel auch die Möglichkeit einer Reduzierung der Datendimensionierung über Expertenwissen vorgestellt. Abbildung 27 zeigt die Grundidee der Dimensionsreduzierung im Rahmen der vorgestellten Systemarchitektur (vgl. Kapitel 5.1). Unter Anwendung entsprechender Methoden erfolgt die Datenvorverarbeitung der jeweiligen Merkmalsdatenvektoren und damit die Reduzierung auf einem sogenannten aggregierten Merkmalsdatenvektor der externen Variablen.

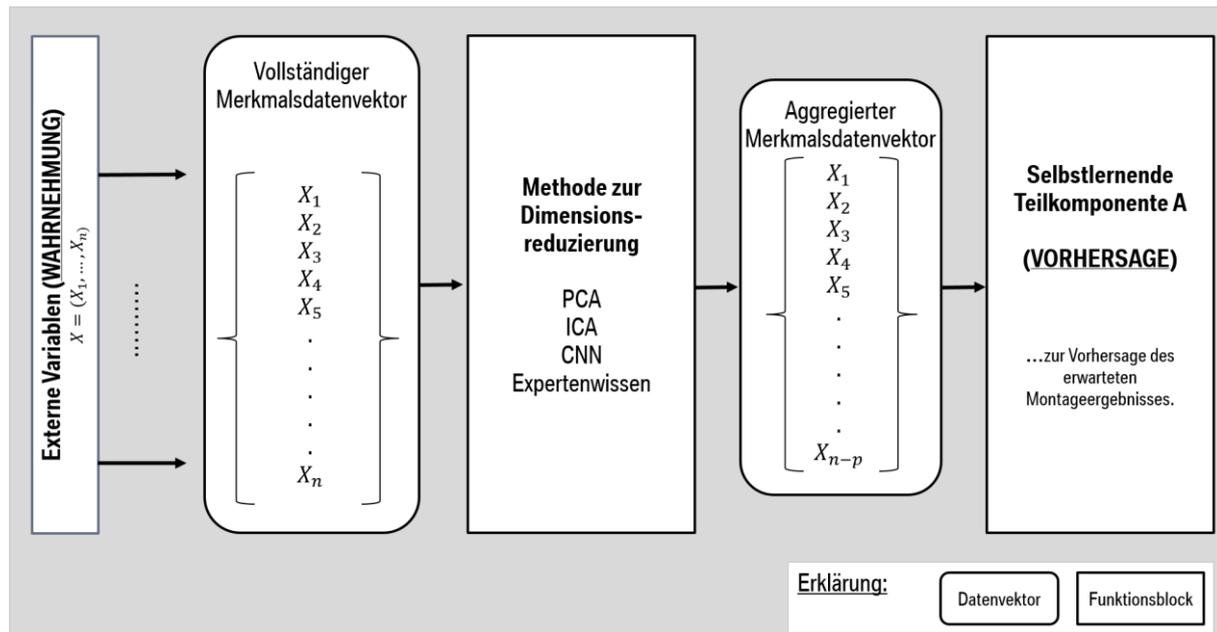


Abbildung 27: Erzeugung eines aggregierten Merkmalsdatenvektors mit Hilfe von Methoden der Dimensionsreduzierung.

### 5.3.1 Dimensionsreduzierung über maschinelle Verfahren

Die Principal Component Analysis (dt. Hauptkomponentenanalyse), kurz PCA, sowie die Independent Component Analysis (dt. Unabhängigkeitsanalyse), kurz ICA, sind etablierte statistische Methoden zur Vereinfachung von Datenmengen über eine Dimensionsreduzierung der ursprünglichen Datenmenge (vgl. Hammer und Villmann 2002, S. 1060).

Das Grundziel von PCA ist die Extraktion der relevanten Informationen aus einer Datenmenge und die Wiedergabe dieser in einem neuen kleineren Variablen­set, den sogenannten Hauptkomponenten. PCA bedient sich existierender Varianzen und Korrelationen in der Grunddatenmenge und erzeugt daraus über die Hauptkomponenten eine nicht miteinander korrelierende kleinere Variablenmenge, deren Variablen absteigend gut die Variabilität der Grunddatenmenge abbilden. Im Fall von PCA wird somit eine endliche Matrix abhängiger Variablen über das Produkt zweier kleinerer Datenmatrizen approximiert, sodass möglichst wenige Informationen verloren gehen. Die erzeugten Hauptkomponenten ergeben sich als Linearkombinationen der Originalvariablen. (vgl. Jolliffe 2002, S. 2–5; Abdi und Williams 2010, S. 434–436)

Für eine detailliertere Erklärung und Interpretation zu PCA sei an dieser Stelle verwiesen auf Jolliffe (2002).

Das Grundvorgehen von ICA ähnelt dem beschriebenen Vorgehen von PCA, jedoch unterscheidet sich ICA in der Zielsetzung. Grundziel von ICA ist die Transformation der bestehenden Datenmenge, sodass die aus der Linearkombination entstehenden Komponenten zueinander maximal statistisch unabhängig sind. Es handelt sich bei ICA somit um einen speziellen Fall der Redundanzreduktion. (vgl. Hyvärinen 1997, S. 2)

Steht bei PCA die Variabilität der Datenmenge im Vordergrund, so fokussiert ICA die statistische Unabhängigkeit der entstehenden Repräsentation. Beide Verfahren haben sich in der wissenschaftlichen Literatur heutzutage weit etabliert. PCA bietet dabei insbesondere Vorteile für Klassifizierungsaufgaben multivariater Bilderverarbeitung (vgl. Wold et al. 1987, S. 50).

Eine weitere und besondere Form der Datenvorverarbeitung stellt die Anwendung von Convolutional Neural Networks (kurz CNN) dar. CNNs sind eine spezialisierte Form neuronaler Netze, welche insbesondere für die Verarbeitung netzähnlicher Datenstrukturen wie Zeitreihendaten oder 2-dimensionale Bilder geeignet sind. CNNs unterteilen sich typischerweise in eine oder mehrere Convolutional-Schichten, welche sich jeweils wiederum in 3 Stufen untergliedern lassen: In der ersten Stufe erfolgt die eigentliche „Convolution“. Hierbei entstehen lineare Aktivierungen, die in der zweiten Stufe durch nicht lineare Aktivierungsfunktionen verarbeitet werden. Über die Pooling-Schicht erfolgt anschließend eine Anpassung der Ausgangsgrößen unter Berücksichtigung der umliegenden Outputs. Innerhalb einer CNN-Struktur ist zudem nicht jedes Eingangsneuron mit einem jeden Ausgangsneuron in Interaktion. Diese Form der spärlicheren Vernetzung wird erreicht, indem der sogenannte Kernel kleiner dimensioniert wird als der Dateninput. CNNs ermöglichen die Erkennung relevanter Bildinformationen wie Kanten und Konturen aus einer hochdimensionalen Menge zu betrachtender Pixel eines Bildes. Ähnlich wie die im Vorhinein beschriebenen Verfahren PCA und ICA reduzieren CNNs also die Menge der zu verarbeitenden Variablen auf wenige Relevante, was zu einer Verbesserung der statistischen Effizienz und der Speicheranforderungen führt (vgl. Goodfellow et al. 2016, S. 326–336).

Mittels einer Kombination eines CNN mit einem Fully-Connected Neural Network (kurz FCNN) wie MLPs besteht somit die Möglichkeit einer Reduzierung hochdimensionaler Datenmengen durch das CNN auf relevante Informationen zur weiteren Verarbeitung im MLP. Abbildung 28 zeigt eine schematische Darstellung dieses hier vorgeschlagenen Ansatzes.

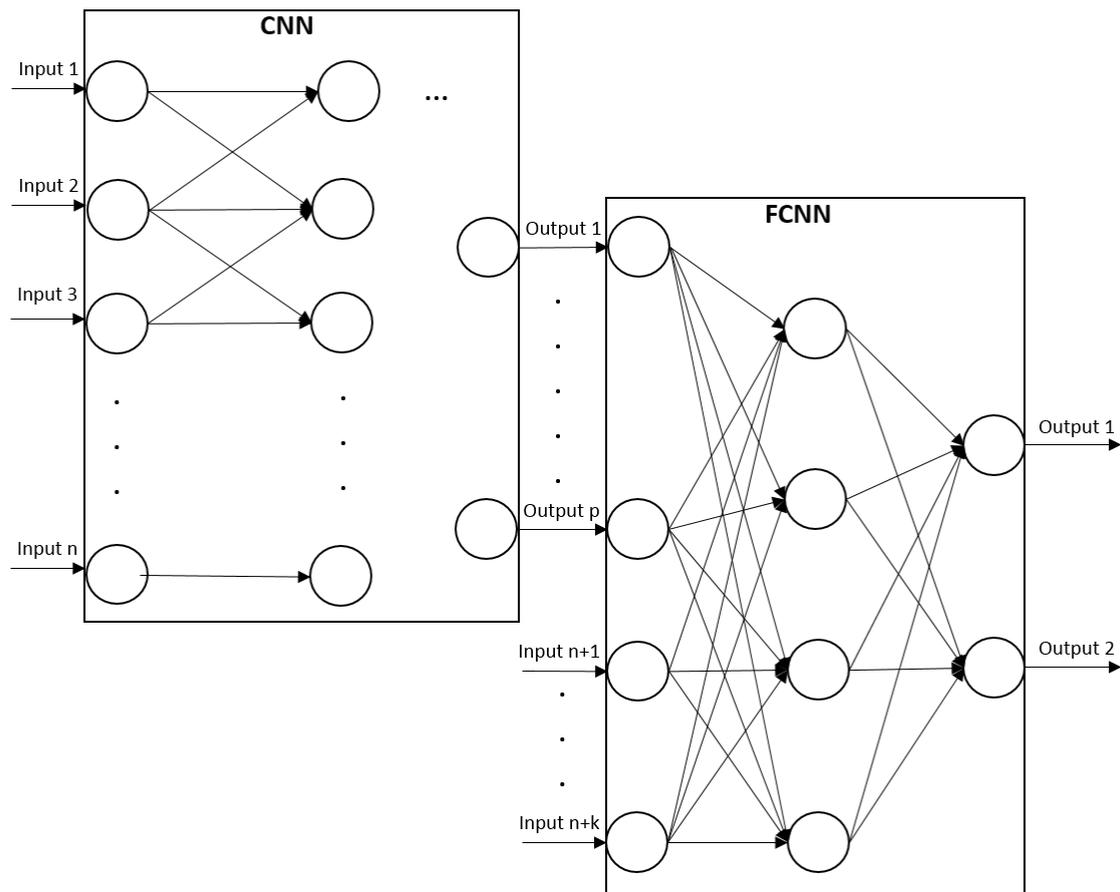


Abbildung 28: Kombinierte Datenverarbeitung über CNN und FCNN.

Für eine detaillierte Beschreibung zur exakten Funktionsweise von CNNs sei an dieser Stelle auf Goodfellow et al. (2016) verwiesen.

### 5.3.2 Dimensionsreduzierung mit Hilfe von Expertenwissen

Neben der Möglichkeit einer Dimensionsreduzierung über maschinelle Verfahren existiert ein weiterer vielversprechender Ansatz in der Dimensionsreduzierung mit Hilfe von Expertenwissen. Im beschriebenen Anwendungsfall automatisierter Montageanlagen in der Automobilproduktion ist es denkbar, dass eine externe Einflussvariable nicht ohne weiteres über einen oder wenige numerische Werte erfasst werden kann. Ein gutes Beispiel für solche externe Variablen ist die Erfassung äußerer Zustände über kamerabasierte Bilderfassung. Häufig ist im beschriebenen Fall jedoch nur ein Teil der gesamthaften Pixeldaten von Relevanz. Über die Anwendung von Expertenwissen können in diesen Fällen die für den Montageprozess vermeintlich relevanten Bildcharakteristika von nicht relevanten getrennt

werden und anschließend nur dieser relevante Informationsanteil im Rahmen des aggregierten Merkmalsdatenvektors der selbstlernenden Teilkomponente zur weiteren Verarbeitung zur Verfügung gestellt werden.

## 5.4 Zusammenfassung des Systementwurfs

Im vorliegenden Kapitel erfolgte die Vorstellung und Beschreibung des entwickelten Konzeptes zur Umsetzung eines selbstlernenden automatisierten Montagesystems zur Fehlervermeidung im Produktionsanlauf.

Die Realisierung einer eigenständig selbstlernenden Fehlervermeidung stellt dabei eine absolute Neuheit dar. Im aktuellen Stand der Forschung sowie Stand der Technik bestehender Systemeigenschaften im Produktionsanlauf von Montagesystemen existieren derartige Systemfähigkeiten bisher nicht.

Das entwickelte System verfolgt dabei eine vom Menschen abgeleitete und damit einfach nachvollziehbare Handlungsstrategie. Das System weicht von einer gegebenen Montagestrategie nur für den Fall ab, dass über die Betrachtung der externen Variablen vom System selbst ein Fehler vorhergesagt wird. Um diesen Fehlerfall zu vermeiden leitet das System vor Ausführung des Montagevorgangs eigenständig eine Gegenmaßnahme ein und lernt dabei, welche der zur Verfügung stehenden Gegenmaßnahmen in welchem Systemzustand den Fehler bestmöglich vermeiden.

Hierfür wurde im Rahmen der Grundsystemarchitektur eine Unterteilung in eine fehlervorhersagende und eine fehlervermeidende Systemkomponente vorgenommen. Weiterhin wurden alle in Kapitel 3 dieser Arbeit abgeleiteten Anforderungen im Systementwurf berücksichtigt und realisiert. Die Gesamtzielsetzung einer Störungsrobustheit neuartiger automatisierter Montagesysteme wurde über die Implementierung maschineller Lernalgorithmen realisiert. Hierdurch werden sowohl eine selbstlernende Fehlervorhersage sowie eine selbstlernende Fehlervermeidung des Gesamtsystems möglich. Anschließend erfolgte die Diskussion geeigneter Algorithmen des maschinellen Lernens aus dem Umfeld des Supervised Machine Learning sowie die Identifikation des besten Algorithmus für die Umsetzung der selbstlernenden fehlervorhersagenden Komponente aus der ursprünglich identifizierten Teilmenge möglicher Algorithmen. Die Auswahl eines maschinellen Lernverfah-

rens für die Realisierung der fehlervermeidenden Eigenschaften erfolgte auf Basis der Vereinbarkeit einer durchgängigen Systemarchitektur und einer kontinuierlichen Lernfähigkeit über den Ansatz Deep Q-Learning. Weiterhin ermöglicht der beschriebene Ansatz über eine Funktionsapproximation der zu erwarteten Belohnung mittels neuronaler Netze auch bei einer großen Menge möglicher Systemzustände und auch bei geringer Datenquantität bereits gute Resultate und erlaubt damit eine sinnvolle Anwendung von Reinforcement Learning für die im Rahmen dieser Arbeit betrachteten Produktionsanlaufprozesse. Im weiteren Verlauf des Kapitels wurde anschließend der Ansatz einer Dimensionsreduzierung durch geeignete existierende mathematische Ansätze oder mit Hilfe von Expertenwissen aufgezeigt. Über eine derartige Informationsvorverarbeitung steigt die statistische Effizienz der angewendeten Algorithmen bei einer damit gleichzeitig sinkenden Anforderung an den notwendigen Systemspeicher. Abbildung 29 zeigt den aus diesen Überlegungen abgeleiteten Gesamtsystementwurf eines selbstlernenden automatisierten Montagesystems zur störungsbedingten Fehlervermeidung im Produktionsanlauf.

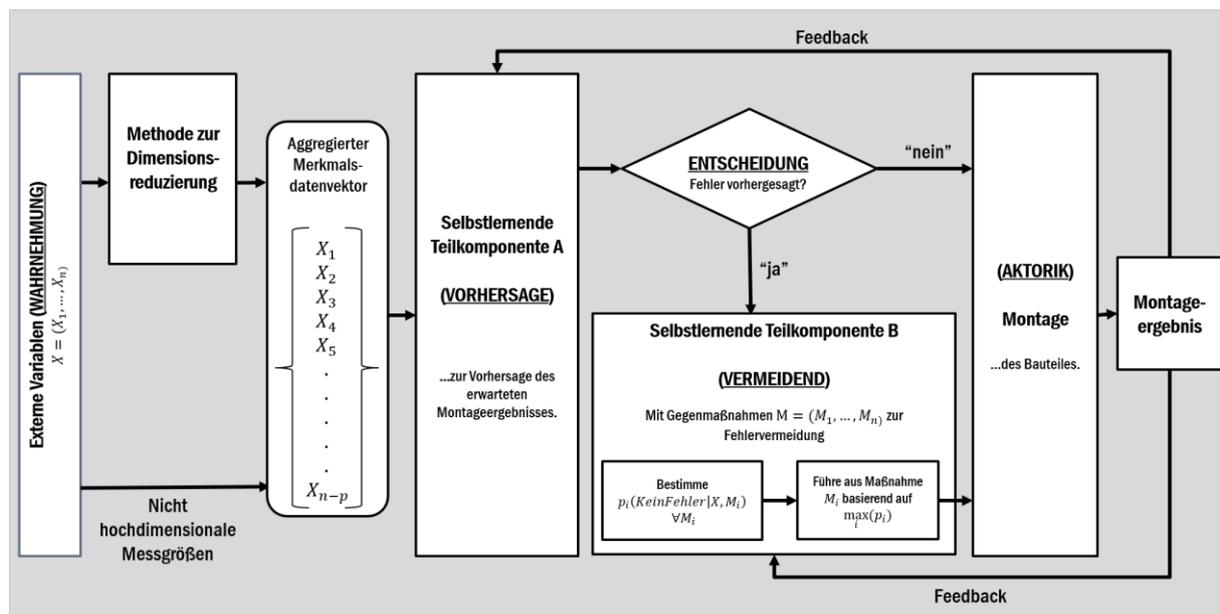


Abbildung 29: Gesamtsystemarchitektur eines selbstlernenden automatisierten Montagesystems mit Datenverarbeitung.

## 6 Prototypische Umsetzungen, Untersuchungen und Ergebnisse

Auf Basis des im vorliegenden Kapitel 5 beschriebenen Systementwurfs erfolgt an dieser Stelle die Beschreibung der prototypischen Umsetzung am Beispiel der automatisierten Stopfenmontage in der Automobilendmontage. Hierfür wird zunächst die generelle Motivation und Übertragbarkeit des entwickelten Ansatzes selbstlernender fehlvermeidender Montagesysteme argumentiert und das anschließende prozessuale Vorgehen über ein Stufenmodell beschrieben. Im nächsten Schritt wird der ausgewählte Realprozess der automatisierten Stopfenmontage näher erläutert und es erfolgt die detaillierte Beschreibung der konzeptionierten Versuchsanlage und der damit erhobenen Versuchsdatenmenge. Anhand dieser findet eine Bewertung und Bestätigung der aufgestellten Hypothesen statt. Über eine Betrachtung der prototypisch erreichten Ergebnisse wird final die generelle Eignung des entwickelten Systementwurfs aufgezeigt.

### 6.1 Motivation und Übertragbarkeit des entwickelten Systementwurfs

Abbildung 30 zeigt den realen Verlauf der Fehlerquote einer roboterbasierten Montageprozessanlage beim ersten Serienanlauf der neuen Technologie in der Endmontage eines Serienwerks der Automobilproduktion. Als Fehler galt dabei, wenn der automatisierte Montageprozess gar nicht oder nicht vollständig erfolgreich ausgeführt wurde.

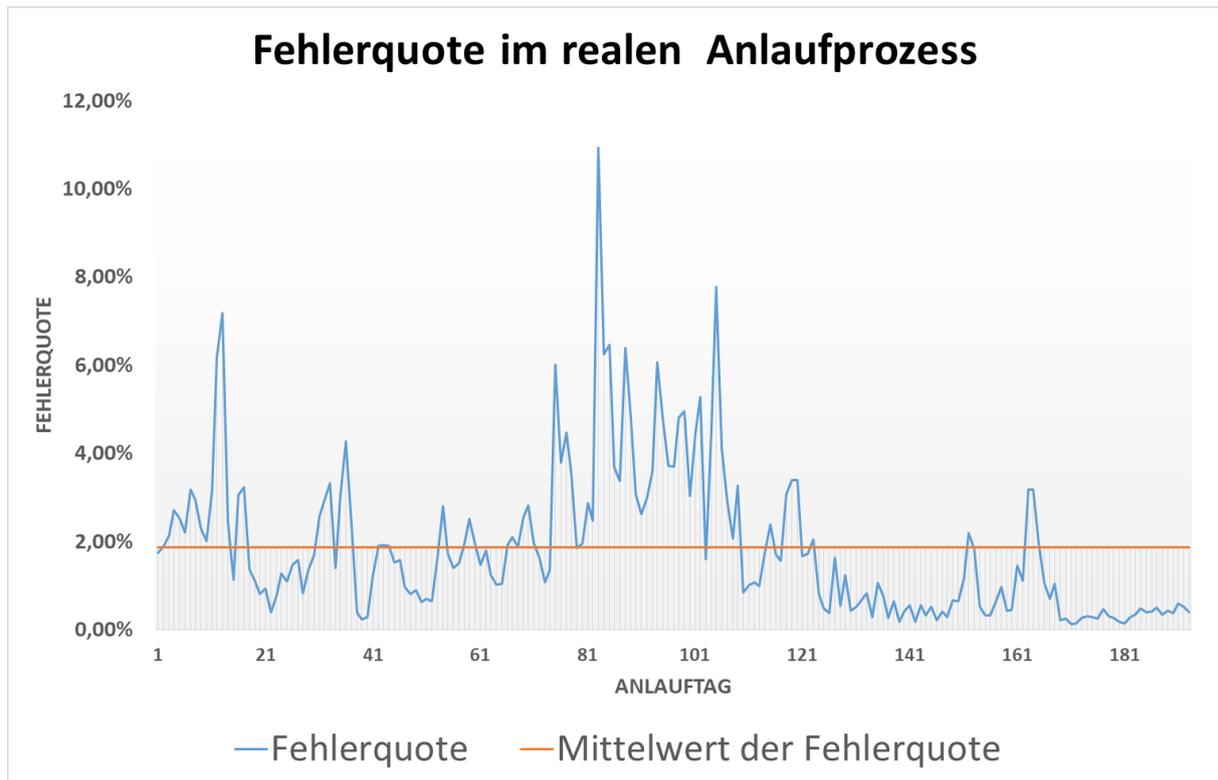


Abbildung 30: Reale Fehlerquote im ersten Produktionsanlauf des automatisierten Stopfensetzens mittels sensibler Robotik.

Aus Abbildung 30 wird gut ersichtlich, dass es zwischen Anlauftag 81 und Anlauftag 110 zu einem tageweisen starken Anstieg der realen Fehlerquote gekommen ist. Da in diesem Zeitraum die interne Anlagenkonfiguration und die Anlagenparameter gar nicht oder nur vereinzelt und jeweils für einen Zeitraum von mehreren Tagen verändert wurden, entfällt dies als Erklärungsursache für die Beobachtungen. Die empirischen Beobachtungen legen vielmehr nahe, dass die Ursache in einer oder mehreren stark schwankenden externen Einfluss-/Störgrößen innerhalb des automatisierten Montageprozesses zu liegen scheint. Weiterhin zeigt der reale Verlauf der Fehlerquote, dass Anlaufschwierigkeiten einer roboterbasierten Montageprozessanlage im ersten Produktionsanlauf der betrieblichen Praxis weit über den Zeitraum der Inbetriebnahme beim Kunden (vgl. Kapitel 2.2) hinausgehen können.

Derartige Anlaufschwierigkeiten sind in der betrieblichen Praxis keine Seltenheit sondern stellen ein häufig beobachtbares Phänomen dar, welches seinerseits zu einer nicht erfolgreichen Erreichung der wichtigen Anlaufziele in mehr als der Hälfte der realen Anlauffälle führt (vgl. Kapitel 2.2.1). Der in Kapitel 5 dieser Arbeit beschriebene Systementwurf zur Entwicklung selbstlernender fehlervermeidender Montagesysteme im Produktionsanlauf

füllt eine existierende Lücke im Stand der Technik und Forschung (vgl. Kapitel 4.4) und stellt gleichzeitig eine effiziente Lösung für die beschriebene Problemstellung der betrieblichen Praxis dar.

Stufenmodelle sind eine häufig verwendete und effiziente Weise zur Entwicklung und Umsetzung wissensbasierter Systeme (vgl. Keller 2017, S. 78). Die prototypische Umsetzung und Untersuchung der in Kapitel 5 hergeleiteten wissensbasierten Systemarchitektur erfolgt daher im weiteren Verlauf dieser Arbeit anhand eines mehrstufigen Prozessmodelles. Abbildung 31 zeigt das für diese Arbeit hergeleitete Prozessstufenmodell in 10 Schritten.

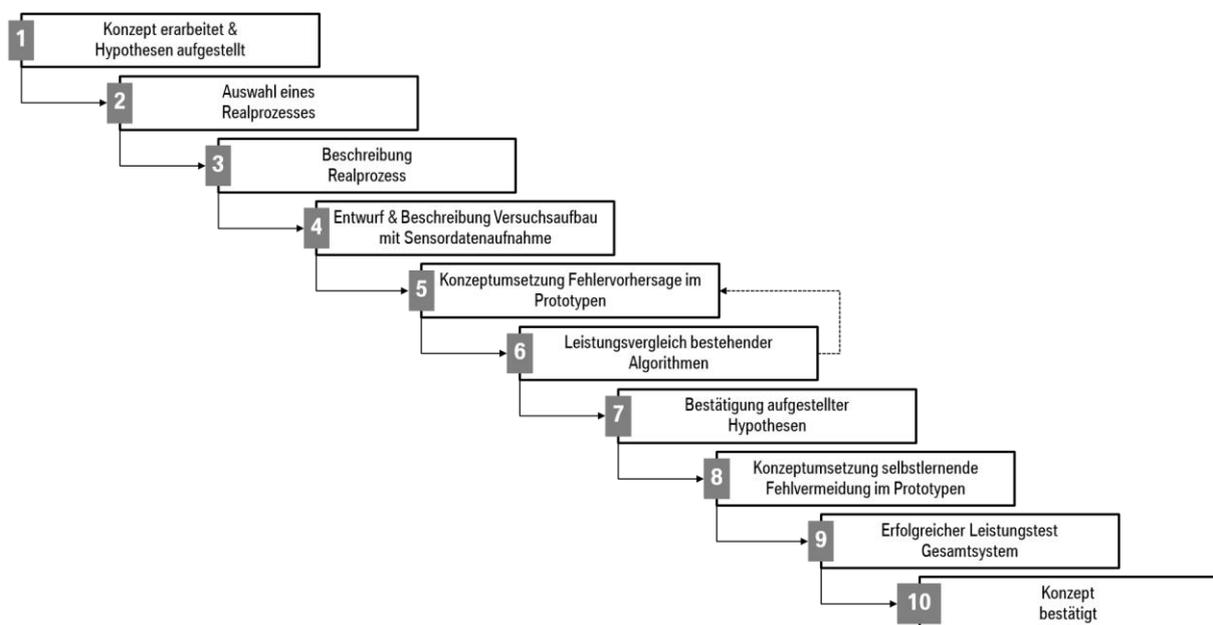


Abbildung 31: Prozessstufenmodell zur prototypischen Umsetzung selbstlernender fehlvermeidender Montagesysteme im Produktionsanlauf.

Zu Beginn hat eine Konzepterarbeitung und Aufstellung entsprechender Hypothesen zur Wirksamkeit des erarbeiteten Konzeptes stattgefunden. Im konkreten Fall der vorliegenden Arbeit umfasst dieses die Entwicklung selbstlernender fehlvermeidender Montagesysteme im Produktionsanlauf (vgl. Kapitel 5). Der dafür entwickelte Ansatz berücksichtigt die Fehlervorhersage aufgrund sich verändernder externer Einflussfaktoren auf den Montageprozess und eine anschließende selbstlernende und eigenständige Fehlervermeidung über die Einleitung einer Gegenmaßnahme auf den auszuführenden Montagevorgang. Im Gesamtumfeld roboterbasierter Montageprozesse eignet sich der entwickelte Ansatz somit für alle kraftsensitiven Montageprozesse, da hierbei über eine Veränderung der Montagekraft eine sinnvolle Gegenmaßnahme auf Veränderungen existiert. Sowie für alle Prozesse in denen

eine Nachpositionierung innerhalb des Endeffektors oder seitens des Roboters eine sinnvolle Reaktion auf die beschriebenen stattfindenden Veränderungen der externen Einflussfaktoren darstellt.

Das beschriebene Konzept ist somit generell übertragbar auf alle existierenden sowie zukünftig zu entwickelnden kraftsensitiven Montagevorgänge mittels Roboter in denen eine Schwankung der äußeren Bedingungen zu einem Fehlerfall im Montagevorgang führen kann. Beispielsprozesse für diese Form der Automatisierung ist die Montage elastisch verformbarer Anbauteile zur Schall- und Feuchtigkeitsisolation. In diese Kategorie fallen Anbauteile wie Türschallisierungen, Pads, Stopfen und Dichtungen. Das entwickelte Konzept ist weiterhin übertragbar auf alle Klipstätigkeiten von Kunststoffanbauteilen wie Spreizmuttern, Montageklipsen und allen weiteren verwendeten Kunststoffabdeckungen die über ein Verrasten montiert werden.

Als weitere nächste Schritte des Stufenmodelles erfolgen die Auswahl und die Beschreibung eines passenden Realprozesses. Im konkreten Fall dieser Arbeit wurde die automatisierte Montage von Verschlussstopfen aus der beschriebenen Menge übertragbarer Realprozesse ausgewählt und im darauf folgenden Kapitel 6.2 näher beschrieben. Im Anschluss erfolgen Entwurf und die Beschreibung eines Versuchsaufbaus anhand dessen im nächsten Schritt die Umsetzung des entwickelten Konzeptes zur Fehlervorhersage erfolgt. Aufbauend darauf findet ein Leistungsvergleich bestehender Algorithmen an der Versuchsanlage statt, anhand dessen eine Bestätigung oder Verwerfung der aufgestellten Hypothesen durchgeführt wird. Abschließend wird die Konzeptumsetzung der selbstlernenden Fehlvermeidung durchgeführt, an die sich ein Leistungstest des Gesamtsystems anschließt und bei positivem Verlauf eine Gesamtkonzeptbestätigung darstellt.

Der weitere Verlauf dieses Kapitels folgt diesem beschriebenen Stufenmodell beginnend bei Schritt 2 - der Auswahl und Beschreibung eines Realprozesses.

## 6.2 Auswahl und Beschreibung eines Realprozesses - Automatisierte Montage von Verschlussstopfen

### 6.2.1 Allgemeines

In den vorgelagerten Kapiteln dieser Arbeit konnte bereits aufgezeigt werden, dass über eine neue Generation sensitiver Roboter zukünftig ein noch breiteres Aufgabenspektrum an Montageaufgaben für die Anwendung automatisierter Montagesysteme erschließbar sein wird. Das kraftsensitive Fügen biegeschlaffer Bauteile (Elastomere) wie Verschlussstopfen stellt eine dieser neuen prozessualen Möglichkeiten dar, welche durch die Anwendung sensitiver Robotik besser möglich werden und deren Automatisierung in der Vergangenheit eine Herausforderung für die Automatisierung in der Automobilindustrie darstellte (vgl. Abbildung 30, Seite 85). Der Begriff Verschlussstopfen bezeichnet dabei ein formfestes, aber elastisch verformbares Anbauteil bestehend aus einer Polyetheresterelastomer-Mischung. Die Montageaufgabe besteht darin, dieses Bauteil durch das Ausüben von Kraft in einem fest spezifizierten kreisrunden Loch eines Karosseriebauteils zu hinterrasten. Abbildung 32 zeigt eine schematische Darstellung des Verschlussstopfens im unverbauten sowie verbauten Zustand im Karosserieblech im Querschnitt.

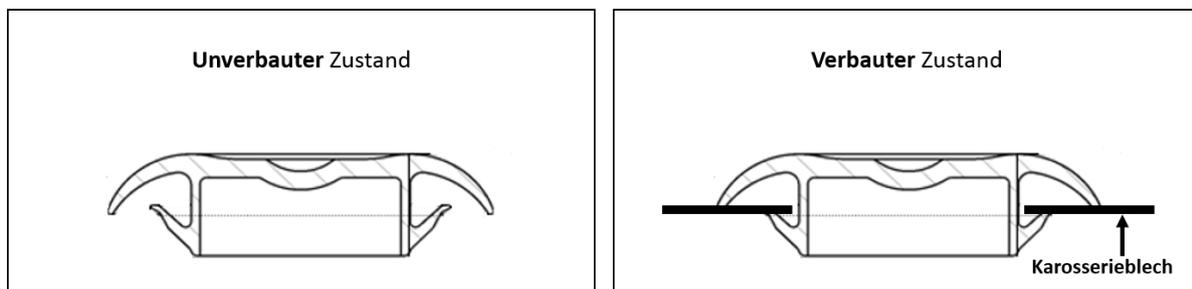


Abbildung 32: Verschlussstopfen im unverbauten und verbauten Zustand. Eigene schematische Darstellung.

Die Verschlussstopfen erfüllen dabei wichtige Aufgaben hinsichtlich Nässe- und Schallisolierung im Rahmen der Fahrzeugarchitektur. Eine korrekte und vollständige Montage der Verschlussstopfen ist damit häufig unmittelbar relevant für die wahrgenommene Fahrzeugqualität beim Endkunden.

## 6.2.2 Verwendeter Endeffektor

Für die Montage der Stopfen mittels sensitiver Robotik kommt ein speziell für die Verschlussstopfen entwickelter Endeffektor<sup>2</sup> zum Einsatz. Dieser wird über ein Frontladesystem beladen, kann dabei mehrere Stopfen aufnehmen und diese nachladefrei hintereinander verbauen. Vor der Montage eines Stopfens wird der jeweils vorderste Stopfen über einen am Endeffektor befindlichen elektrischen Antrieb in eine sog. Vorladeposition geschoben. Durch eine geometrische Verjüngung wird der Stopfen dabei am Ausgang des entwickelten Endeffektors gehalten und mittels einer speziellen Gestaltung der Innengeometrie des Werkzeugs erfolgt zusätzlich eine Ausrichtung des Stopfens im Werkzeug hin zu einer Zentrierung. Mit Hilfe einer 2-D-Kamera in Verbindung mit einer am Endeffektor integrierten Lichtquelle erfolgt der letzte Toleranzausgleich bei der Lochfindung vor dem Beginn der Stopfenmontage. Abbildung 33 und Abbildung 34 zeigen den verwendeten Endeffektor. Für weitere Details zu Gestaltung und Aufbau des Endeffektors sowie zum Magazin- und Stapelkonzept sei an dieser Stelle verwiesen auf Bix et al. (2016) und Schönherr et al. (2016).

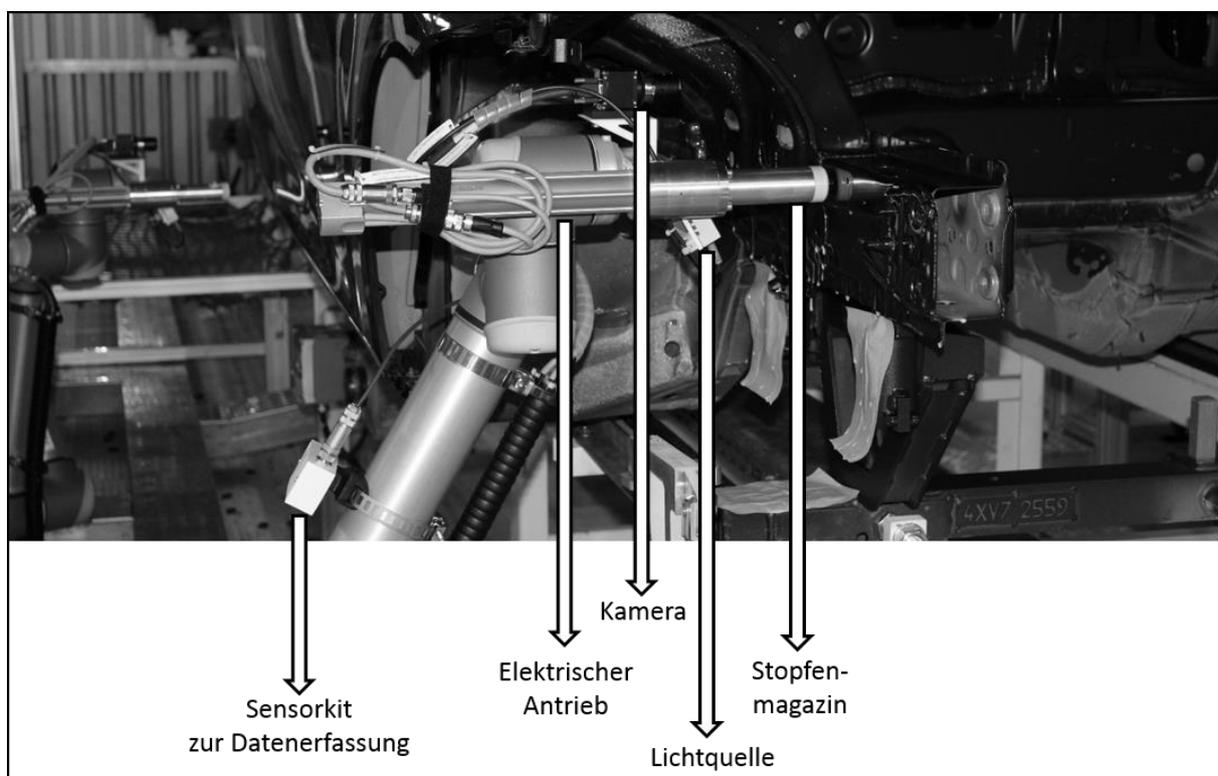


Abbildung 33: Verwendeter Endeffektor zur automatisierten Montage von Verschlussstopfen.

<sup>2</sup> Der Begriff Endeffektor bezeichnet das letzte Element einer kinematischen Kette bestehend aus mehreren starren Körpern, welche durch Gelenke linear miteinander verbunden sind (vgl. Tauber 1990, S. 13).

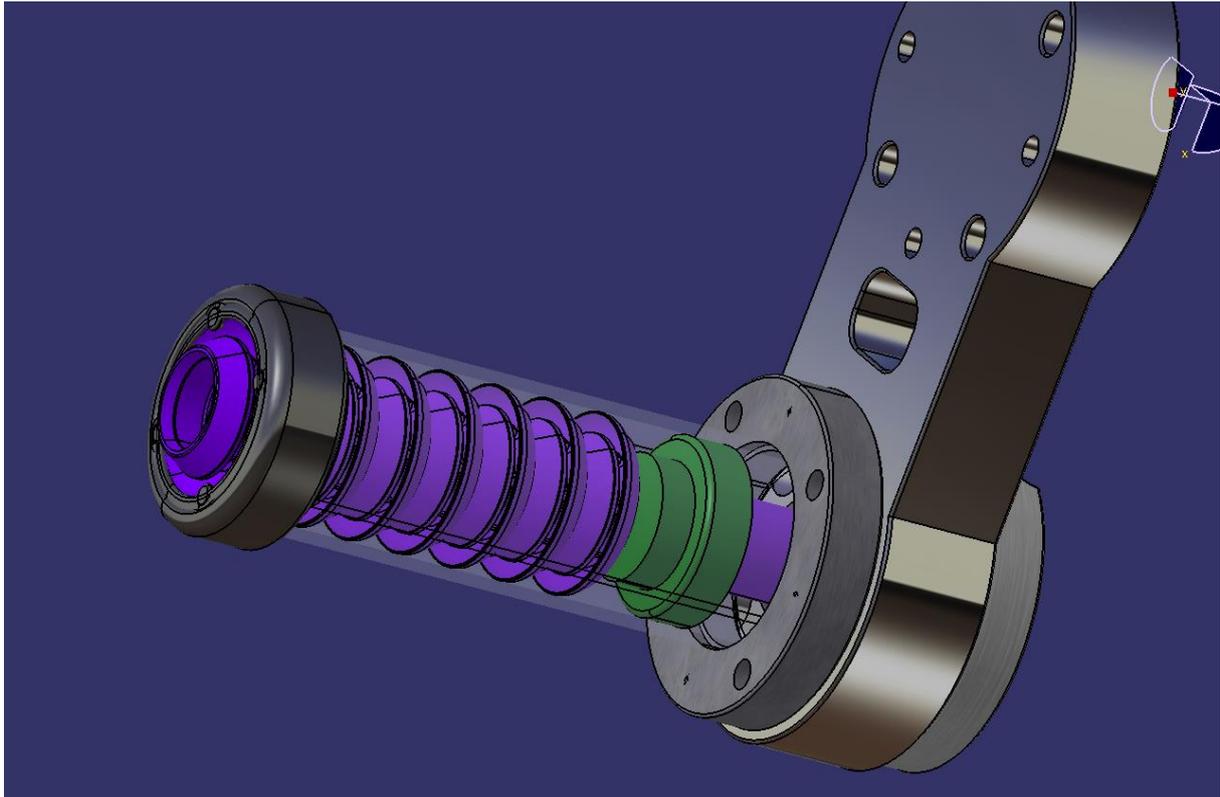


Abbildung 34: Detailansicht Stopfenmagazin des verwendeten Endeffektors zur automatisierten Montage von Verschlussstopfen.

### 6.2.3 Automatisierter Montageprozess mittels sensitiver Robotik

Die prozesssichere Montage eines Verschlussstopfens findet in einem fünfstufigen Gesamtprozess statt. Abbildung 35 zeigt diese Untergliederung des Montageprozesses in die jeweiligen Einzelschritte.

Vor der Montage eines Stopfens befindet sich dieser in Ausgangsposition im Endeffektor und wird zunächst über den Elektroantrieb in die Vorladeposition gebracht. Dabei drückt eine durch den Elektroantrieb ausfahrbare Kolbenstange mittels eines Stößels flächig auf den innersten Verschlussstopfen im Magazin (vgl. Abbildung 34). Die dabei unterschiedlich stattfindende Kompression, je nach Anzahl der noch im Tool befindlichen Stopfen, wird dabei durch eine entsprechend definierte Verfahrstabelle des Elektroantriebs berücksichtigt.

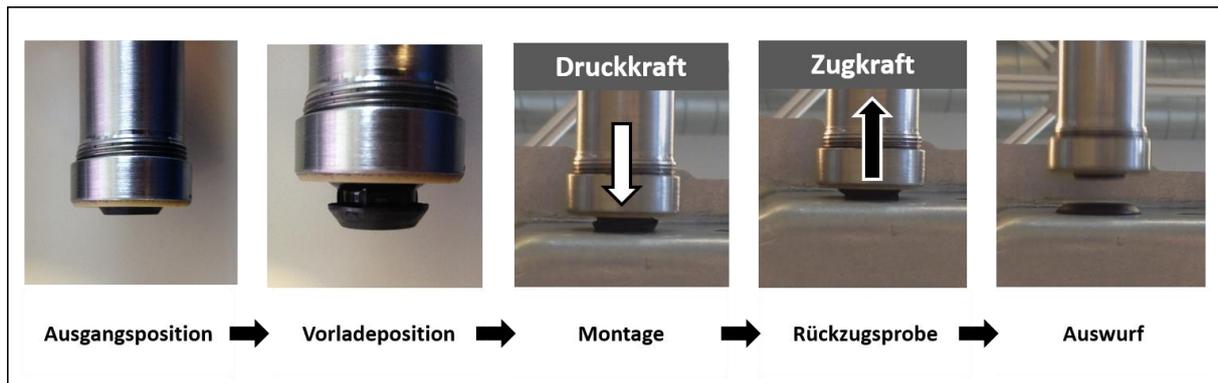


Abbildung 35: Automatisierter Montageprozess zum Setzen von Verschlussstopfen mittels sensitiver Robotik. Nachdem der Stopfen sich in Vorladeposition befindet, wird dieser mittels sensitiver Robotik verbaut. Hierfür wird eine inhärent gemessene Andruckkraft über den Roboter aufgebracht. Nach dem Erreichen des Kraftsollwertes wird anschließend eine Rückzugsprobe ausgeführt. Nach erfolgreichem Erreichen dieses Zugkraftsollwertes wird durch ein weiteres Verfahren des Elektroantriebes der Stopfen aus dem Endeffektor ausgeworfen. Der jeweils nächste Stopfen befindet sich anschließend bereits in Ausgangsposition.

#### 6.2.4 Automatisierte Montage von Verschlussstopfen in der Serienproduktion

Der in den vorgelagerten Kapiteln beschriebene automatisierte Montageprozess wurde in dieser Form in den realen Serienbetrieb eines namhaften deutschen Automobilherstellers überführt. Abbildung 36 gibt einen schematischen Überblick dieser Serienanlage. Im Rahmen des ersten Anlaufs dieser neuen automatisierten Montagetechnologie konnten über den Verlauf der Fehlerquote (vgl. Abbildung 30, S. 85) verschiedene Herausforderungen aufgezeigt werden. Die gewonnenen empirischen Beobachtungen legen dabei nahe, dass eine mögliche Ursache für die Schwierigkeiten im Anlauf in einer oder mehreren stark schwankenden externen Einfluss-/Störgrößen auf den automatisierten Montageprozess zu liegen scheint.

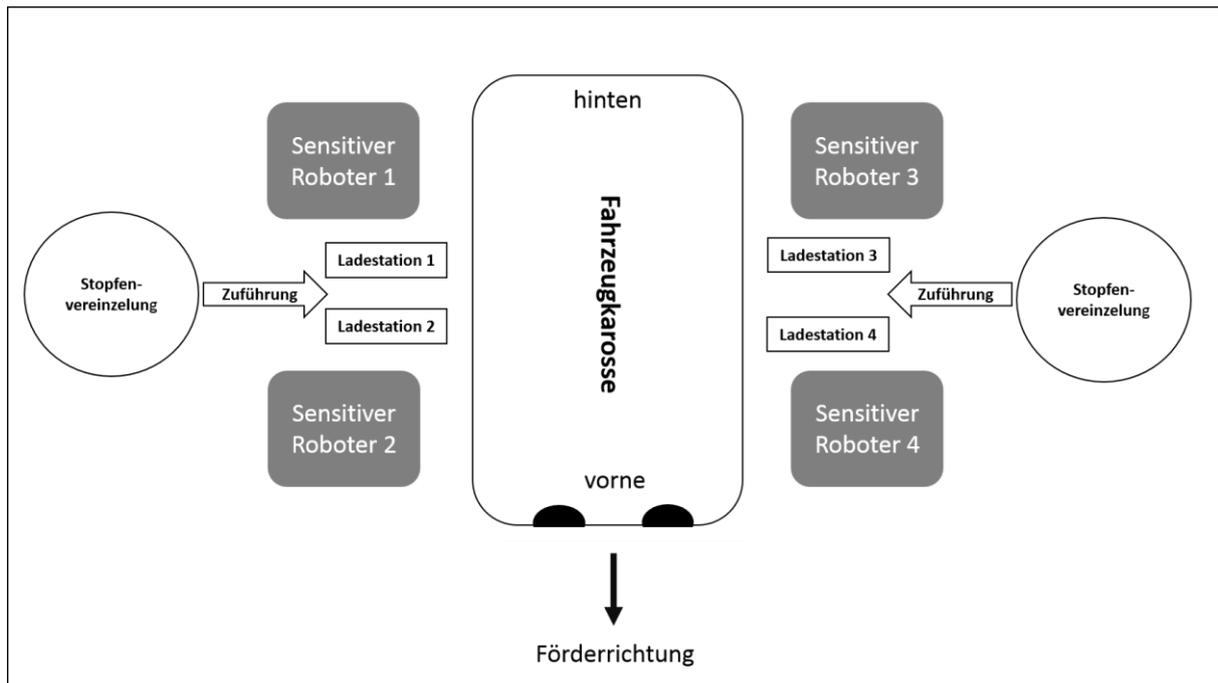


Abbildung 36: Schematische Darstellung der Serienprozessanlage. Eigene Darstellung.

Aufbauend auf diesen Erkenntnissen erfolgt im weiteren Verlauf dieser Arbeit zunächst die Identifizierung möglicher Störgrößen und Umfeldeinwirkungen auf den beschriebenen Prozess und anschließend die Ableitung erfassbarer Messgrößen hierzu. Über die Realisierung eines Versuchsaufbaus unter möglichst ähnlichen Bedingungen wie der hier beschriebenen Serienanlage folgt weiterhin eine Datenaufnahme sowie die Konzeptionierung und Validierung eines selbstlernenden automatisierten Montagesystems am Beispielprozess.

### 6.2.5 Störgrößen und Umfeldeinwirkungen auf den Montageprozess im Anlauf

Scholz-Reiter und Krohne (2010) haben gezeigt, dass mögliche Probleme im Serienanlauf zu Störgrößen und Umfeldeinwirkungen aggregiert und mittels der Darstellungsform des Ishikawa-Diagramms auf einfache Weise transparent gemacht werden können (vgl. Scholz-Reiter und Krohne 2010, S. 13). Für den vorliegenden Prozess erfolgte im Rahmen mehrerer Workshops und unter Einbezug mehrerer Prozessexperten die Dokumentation möglicher Störgrößen und Umfeldeinwirkungen auf den automatisierten Montageprozess. Als Experte galt dabei ein jeder Spezialist aus Planung und Technologieentwicklung, welcher mindestens vier Monate Erfahrung im Themenbereich der automatisierten Stopfenmontage hatte.

Die erhaltenen Ergebnisse wurden dabei in Anlehnung an Scholz-Reiter und Krohne (2010) den Bereichen Maschine, Material, Mensch, Methode und Mitwelt zugeordnet. Auf die Aspekte Management, Prozesse und Umfeld wurde aufgrund des in dieser Arbeit gelegten Betrachtungsfokus, rein auf Anlagenebene, verzichtet. Abbildung 37 zeigt die darin dokumentierten Störgrößen und Umfeldeinwirkungen im AnlaufszENARIO.

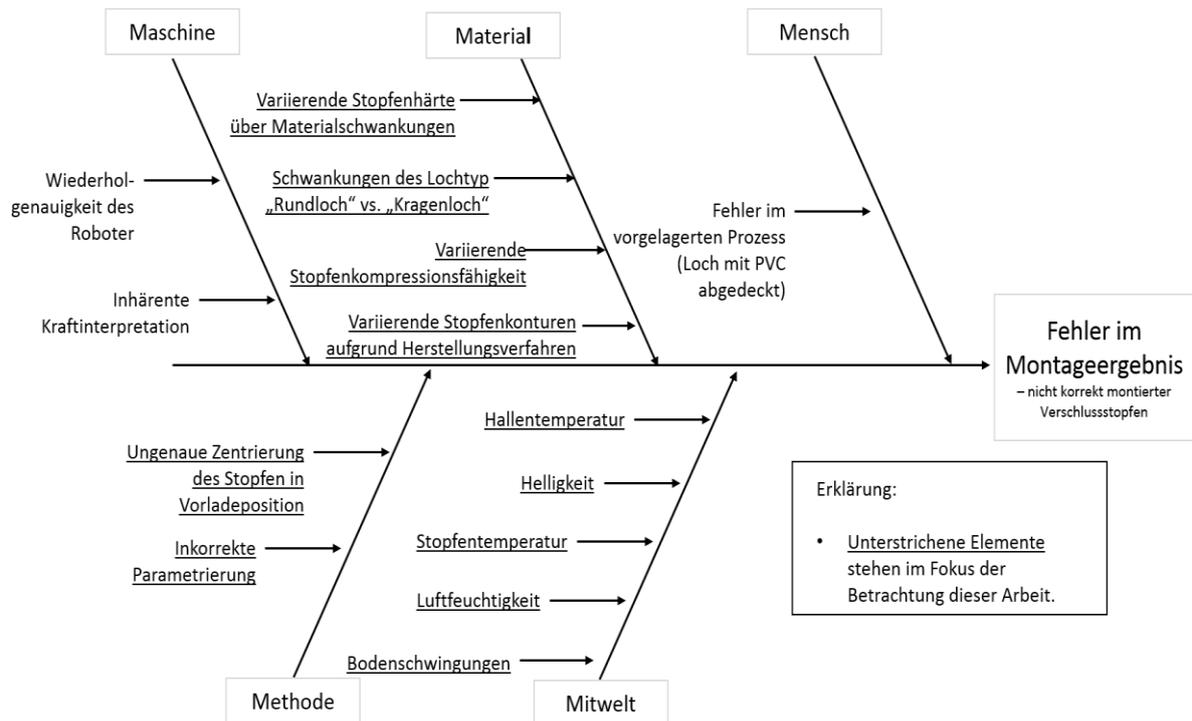


Abbildung 37: Störgrößen und Umfeldeinwirkungen der automatisierten Stopfenmontage im Anlauf.

Gemäß der Zielsetzung dieser Arbeit erfolgte anschließend eine weitergehende Eingrenzung auf die Bereiche Material, Mitwelt und Methode. Die Bereiche Material und Mitwelt repräsentieren natürlich variierende unvermeidbare externe Einflussfaktoren. Der Bereich Methode betrifft den in dieser Arbeit gewählten Lösungsansatz einer selbstlernenden Parametrierung sowie eine weitere Störgröße, welche über eine Veränderung der Bereiche Mitwelt und Material direkt beeinflusst wird.

Basierend auf den identifizierten relevanten Störgrößen und Umfeldeinwirkungen (vgl. Abbildung 37) erfolgte anschließend im Rahmen eines Expertenworkshops die Ableitung möglichst einfach erfassbarer Messgrößen im Realprozess je Umfeldeinwirkung bzw. Störgröße. Tabelle 2 zeigt das Ergebnis dieser Ableitung. Dabei ist auffallend, dass mehrere

identifizierte Störgrößen bzw. Umfeldeinwirkungen durch dieselbe Messgröße berücksichtigt werden können.

Tabelle 2: Ableitung relevanter Messgrößen.

Identifizierte Störgröße/Umfeldeinwirkung	Erfassbare Messgröße
- Variierende Stopfenhärte über Materialschwankungen	- Härte des Stopfens
- Schwankungen des Lochtyps	- Lochtyp
- Variierende Stopfenkompressionsfähigkeit	- Härte des Stopfens, - Bilddaten Stopfen in Vorladeposition
- Variierende Stopfenkonturen	- Bilddaten Stopfen in Vorladeposition
- Hallentemperatur	- Umgebungstemperatur der Anlage
- Helligkeit	- Lichtstärke
- Stopfentemperatur	- Oberflächentemperatur der Verschlussstopfen
- Luftfeuchtigkeit	- Luftfeuchtigkeit
- Bodenschwingungen	- Schwingungsamplituden der Anlage
- Ungenaue Zentrierung des Stopfens in Vorladeposition	- Bilddaten Stopfen in Vorladeposition

Die aus der Ableitung identifizierten externen erfassbaren Einflussvariablen lauten wie folgt:

- Härte der Stopfens,
- Lochtyp,
- Positionierung des Stopfens in Vorladeposition (Bilddaten in 360x360 Pixel),
- Lichtstärke,
- Umgebungstemperatur der Anlage,
- Oberflächentemperatur der Verschlussstopfen,
- Luftfeuchtigkeit,

- Schwingungsamplituden der Anlage.

### **Exkurs Schwingungsamplituden der Anlage:**

Im Rahmen einer detaillierten Schwingungsuntersuchung über einen Zeitraum von 48 Stunden an der Realanlage (vgl. Kapitel 6.2.4) konnten maximale Schwingungsamplituden von  $x < 1,0\text{mm}$  am Roboterendeffektor, Robotersockel sowie am Fahrzeug selbst gemessen werden. Weiterhin konnte über eine detaillierte Versuchsreihe mittels der in Abbildung 46 beschriebenen Fügeversuchsanlage aufgezeigt werden, dass erst bei einem auftretenden Versatz größer 3,5mm zwischen Zentrierung Loch zu Endeffektor der Montagevorgang nicht mehr ausführbar ist. Infolge der ausgeführten Realmessungen konnte somit der reale Störeinfluss über Schwingungsamplituden ausgeschlossen und als vernachlässigbar aufgezeigt werden. Es erfolgt daher im weiteren Verlauf keine Berücksichtigung dieser potentiellen Störgröße.

## **6.3 Entwurf und Beschreibung des Versuchsaufbaus**

### **6.3.1 Allgemeines**

Das im Rahmen dieser Arbeit entwickelte Verfahren zur selbstlernenden Vermeidung störungsbedingter Fehler im automatisierten Montageprozess wird im Rahmen einer Versuchsanlage für die automatisierte Montage von Verschlussstopfen implementiert und validiert. Dabei erfolgt die Aufnahme der Test- und Validierungsdaten ebenfalls anhand der Versuchsanlage. Der experimentelle Aufbau wurde dabei unter möglichst realen Serienbedingungen in einem Produktionsgebäude eines namhaften deutschen Automobilherstellers realisiert.

Abbildung 38 zeigt eine Gesamtübersicht des realisierten Versuchsaufbaus. Der Versuchsaufbau besteht aus einem fest am Boden montierten Teilabschnitt einer Karosse, in welchem Verschlussstopfen automatisiert verbaut werden. Es handelt sich dabei um einen Teilabschnitt einer Originalkarosse, wie diese auch in der Serienanlage (vgl. Kapitel 6.2.4) verwendet wird. Der in 6.2.2 beschriebene Endeffektor wurde an einem sensitiven Leichtbauroboter Universal Robots UR-10 montiert. Die Beladung des Endeffektors erfolgt automatisiert über die Aufnahme eines manuell erzeugten Verschlussstopfenstapels. Über eine SPS findet der Informationsaustausch zwischen dem Roboter und den Elektrokomponenten des

Endeffektors statt. Über ein in der Anlage integriertes Rechnersystem erfolgt die Datenverarbeitung der aufgenommenen Messgrößen. Die Datenübertragung der Sensor- und Messdaten erfolgt dabei über USB an das Rechnersystem oder über manuelle Eingabe. Die Rückmeldung über den Erfolg des Montageprozesses erfolgt manuell über eine Eingabemaske durch den Anlagenbediener nach einer Sicht- und Druckprüfung an der Karosse. Hierbei kann vom Bediener zwischen 3 möglichen Endzuständen ausgewählt werden.

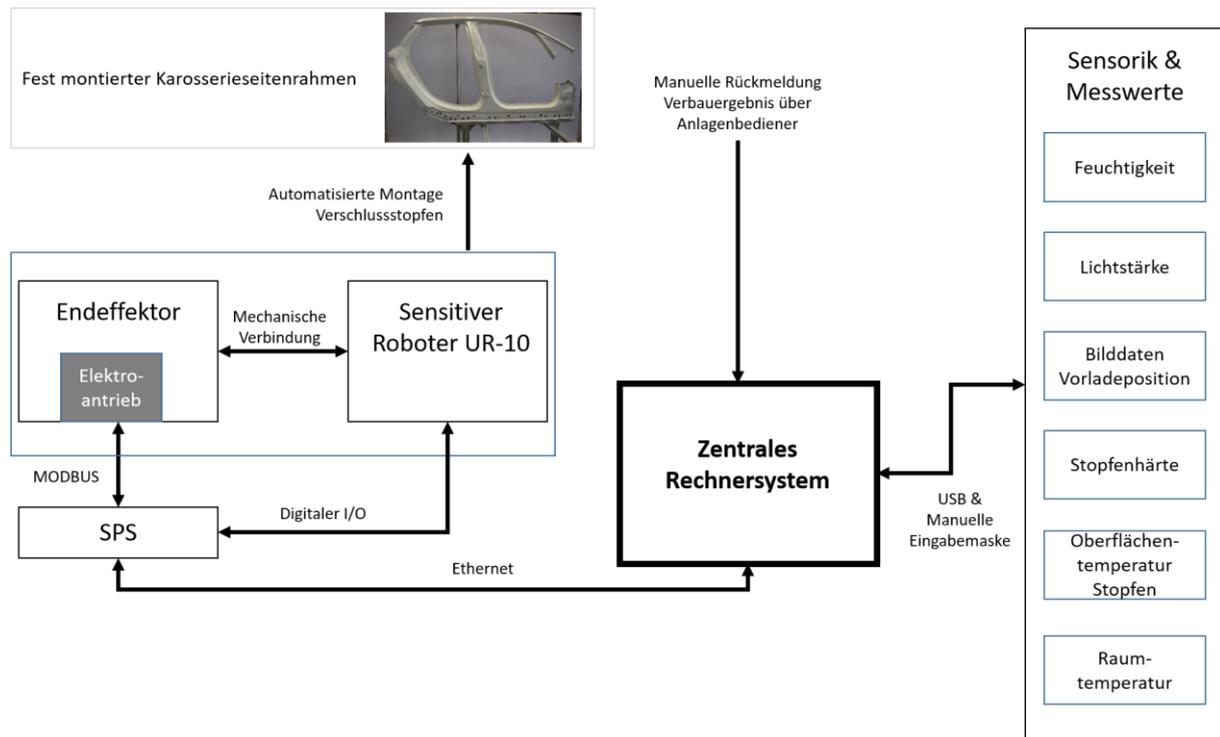


Abbildung 38: Gesamtübersicht des Versuchsaufbaus.

### 6.3.2 Datenaufnahme

Basierend auf den in Abbildung 37 aggregierten unvermeidbaren möglichen externen Ursachen für Fehler im Montageergebnis sowie den in Tabelle 2 abgeleiteten Messgrößen wurden zunächst Versuchsdaten erzeugt. Abbildung 39 zeigt den dafür verwendeten Realaufbau der beschriebenen Versuchsanlage.



Abbildung 39: Realaufbau der Versuchsanlage.

Zur möglichst genauen Aufnahme der Messwerte wurde zu jeder der identifizierten Messgrößen eine passende Sensorik oder ein Messverfahren ausgewählt. Die dabei erfassten Messwerte werden entweder direkt an das zentrale Rechensystem über USB gesendet oder über manuelle Eingaben erfasst. Durch die Entwicklung einer speziellen Eingabemaske wurden dabei mögliche Fehler in der Datenerhebung reduziert. Abbildung 40 zeigt das Ablaufdiagramm zur Datenerhebung eines einzelnen ausgeführten automatisierten Montagevorgangs. Im weiteren Verlauf dieses Abschnitts wird das angewendete Vorgehen für die Versuchsdatenerhebung näher erläutert. Für jeden an der Versuchsanlage ausgeführten Montagevorgang entsteht dabei ein Merkmalsdatenset bestehend aus folgenden Messgrößen:

- Erfasste Stopfenhärte,
- Erfasste Oberflächentemperatur des Stopfens,
- Erfasste Vorladeposition des Stopfens,
- Lochtyp,
- Erfasste Lichtstärke,
- Erfasste Luftfeuchtigkeit,
- Erfasste Raumtemperatur,

- Erreichtes Montageergebnis.

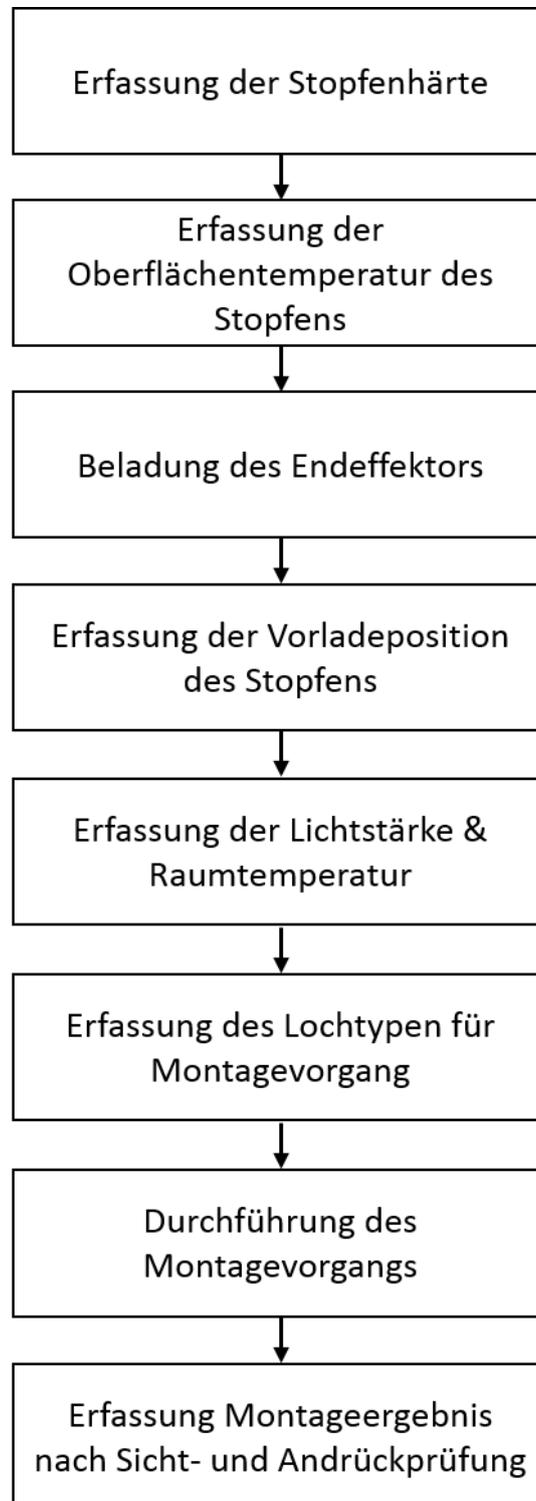


Abbildung 40: Ablaufdiagramm der Versuchsdatenerhebung.

### Erfassung der Stopfenhärte

Aufgrund des vorliegenden Elastomers in Form der Verschlussstopfen wurde zur Härtemessung der Stopfen die SHORE-Härte D<sup>3</sup> als zielführende Messgröße ausgewählt. Zur Berücksichtigung möglicher Härteunterschiede innerhalb des Stopfens erfolgte die Messung manuell an zwei sich gegenüberliegenden Punkten A und B mit einem fixen Abstand von jeweils 6,5 mm zum theoretischen Mittelpunkt der Stopfenoberfläche. Über eine fixierte Aufnahme des Stopfens auf der Grundplatte konnte dieser feste Abstand messtechnisch realisiert werden (vgl. Abbildung 41). Die Messzeit wurde gemäß DIN 53505 auf 3 Sekunden festgelegt. Anschließend erfolgte die Aufnahme beider Messgrößen über eine Eingabemaske (vgl. Abbildung 42). Hieraus wurde anschließend durch das Rechensystem der Mittelwert gebildet und dieser Wert als mittlere Stopfenhärte im Datenset erfasst.

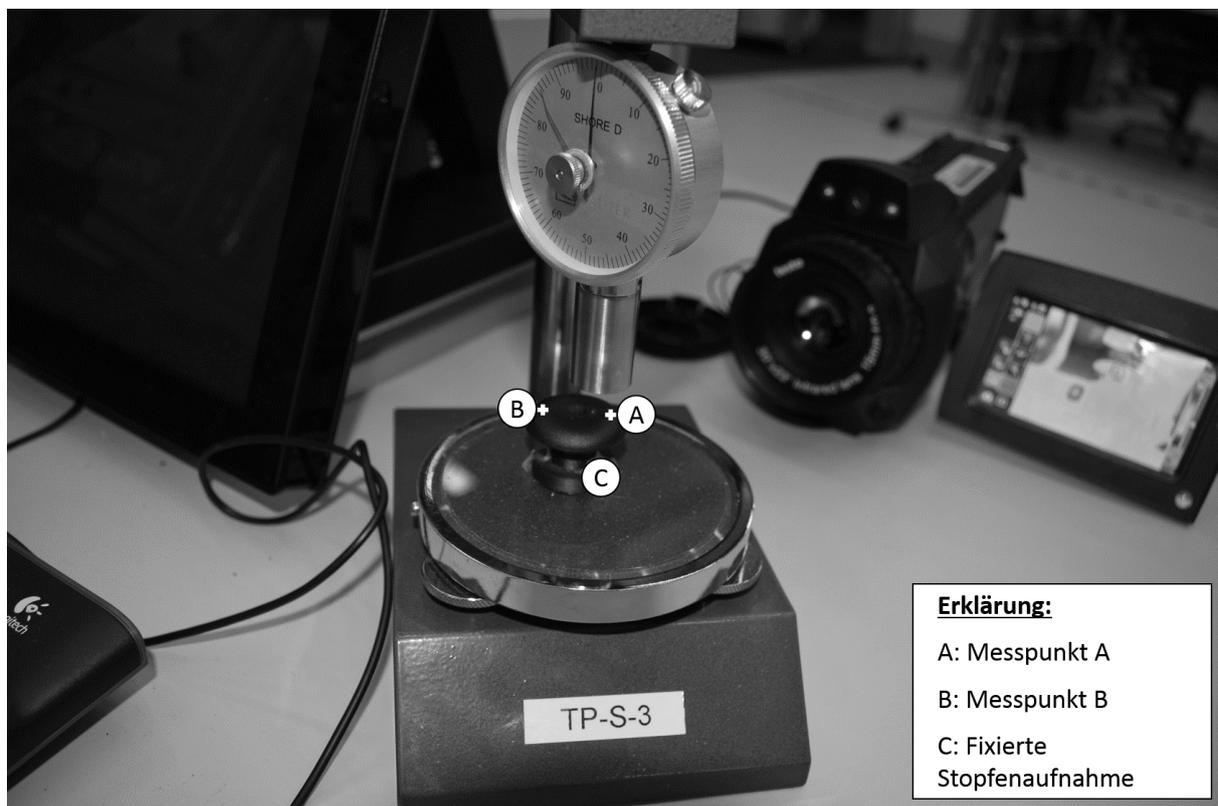


Abbildung 41: Erfassung Stopfenhärte SHORE-Härte D.

Zur Gewährleistung einer möglichst repräsentativen Versuchsdatenerzeugung über unterschiedliche Produktionsbatches des Stopfenherstellers wurde über den Verlauf von 12 Monaten zu unterschiedlichen Zeitpunkten aus unterschiedlichen deutschen Werkstandorten

<sup>3</sup> Benannt nach Albert Ferdinand Shore. Definition gemäß DIN ISO 7619-1 und DIN 54505

Stopfen für die Versuchsanlage ausgefasst und diese stichprobenartig für die Versuche verwendet.

Sample ID	Haartemessung 0	Haartemessung 1	Stopfentemp.
1797	39	38	17.2
1798	40	39	17.6
1799	39	38	18
1800	38	39	17.5
1801	37	38	17
1802	41	40	17.8

----Experimentsetup----

Nächste freie Sample ID: 1797.  
 Starte Experiment.....

Warte auf Verbindung ...  
 Verbunden mit Roboter:192.168.178.8:52517

Roboter bereit zur Beladung... Bitte bestätigen!

**Geladen**

Abbildung 42: Eingabemaske manueller Messwerte.

### Erfassung der Stopfenoberflächentemperatur

Die Erfassung der Oberflächentemperatur erfolgt ebenfalls manuell, mittels einer Wärmebildkamera in °C mit einer Genauigkeit von einer Nachkommastelle. Der Messvorgang wird nach Beendigung der Härtemessungen ausgeführt. Der Stopfen befindet sich dabei noch in der dafür verwendeten Stopfenaufnahme. Als Messpunkt wird ein definierter Punkt im oberen Bereich des Stopfens erfasst (vgl. Abbildung 43). Der Messwert wird ebenfalls über die Eingabemaske (vgl. Abbildung 42) aufgenommen.



Abbildung 43: Erfassung der Stopfenoberflächentemperatur.

### **Erfassung der Vorladeposition des Stopfens**

Der in Tabelle 2 abgeleiteten Vorladeposition des Stopfens als Einflussvariable auf den Montagprozess kommt eine besondere Bedeutung zu, da diese eine mögliche Messgröße für mehrere identifizierte Stör- bzw. Umfeldeinwirkungen darstellt. Variierende Stopfenkompressionsfähigkeiten aber auch Toleranzen in den Stopfenkonturen haben nachvollziehbarerweise einen direkten Einfluss auf die Positionierung des Stopfens in der Vorladeposition. Hierbei waren über einen stichprobenartigen Vorversuch stopfenspezifische Unterschiede in der Positionierung aus dem Tool heraus, aber auch in der Genauigkeit der Zentrierung feststellbar. Weiterhin wird über die Erfassung der Vorladeposition die in Abbildung 37, S. 93 aufgezeigte methodische Störgröße einer ungenauen Zentrierung im Anlauf berücksichtigt. Zur möglichst genauen Erfassung der 3-dimensionalen Orientierung des Stopfens in der Vorladeposition erfolgen dafür Aufnahmen aus drei unterschiedlichen Richtungen. Abbildung 44 zeigt die unterschiedlichen gewählten Aufnahmerichtungen A, B und C. Perspektive A entspricht dabei einer Seitenaufnahme, Perspektive B einer Aufnahme von oben und Perspektive C einer Aufnahme von vorne auf den Stopfen in Vorladeposition.

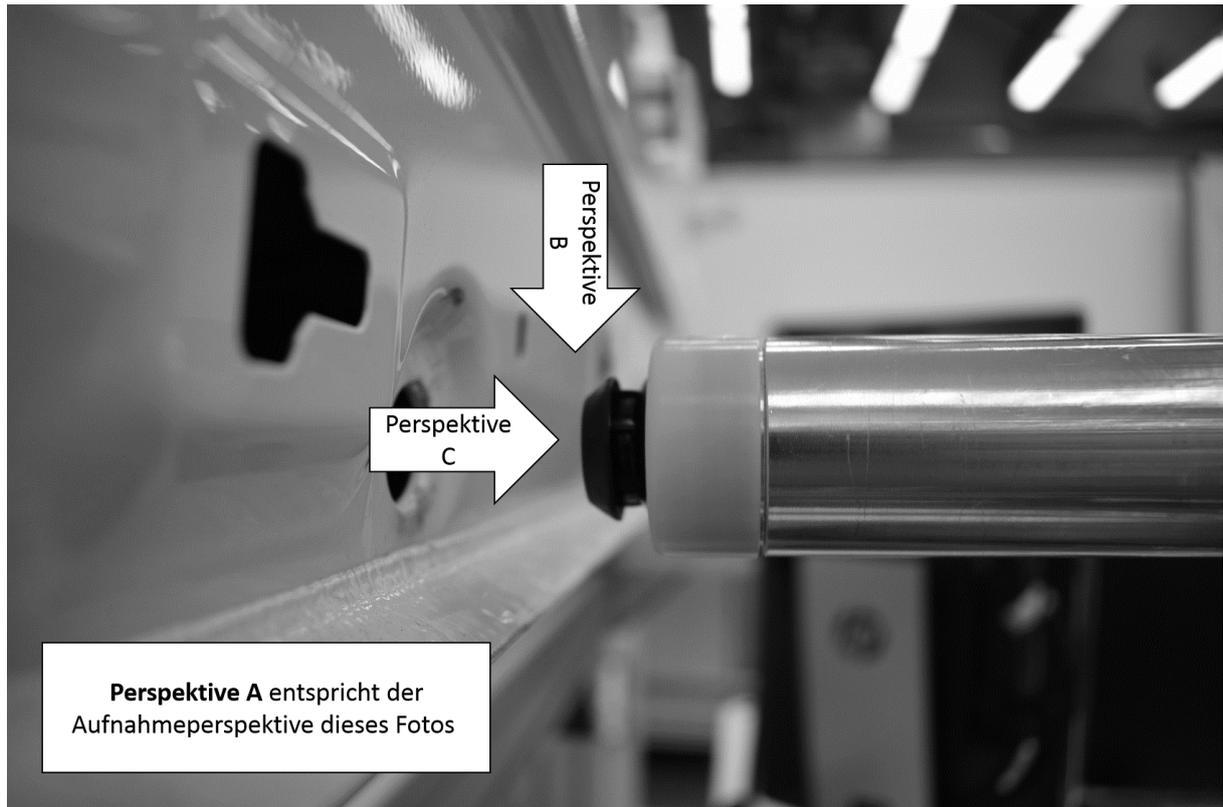


Abbildung 44: Gewählte Perspektiven zur Bestimmung der Stopfenvorladeposition über Bilddaten.

Anschließend erfolgte eine Zusammenfassung der erhaltenen Bildinformationen in ein 360x360 Pixel-Bild. Abbildung 45 zeigt die aggregierten Bildinformationen zweier unterschiedlicher Stopfen in Vorladeposition. Aus diesem Beispiel ist eine unterschiedliche Zentrierung der beiden Stopfen bereits eindeutig erkennbar.



Abbildung 45: Aggregierte Bildinformationen zur Bestimmung der Stopfenvorladeposition.

Zur weiteren Untersuchung des Einflusses der unterschiedlichen Zentrierung des Stopfens wurde in Vorversuchen zunächst damit begonnen, die aufgrund der ungenauen Zentrierung auftretenden „Kippmomente“ im Fügeprozess zu bestimmen. Das Ziel der Vorversuche bestand darin, über eine Bestimmung auftretender Kippmomente auf den Einfluss der Zentrierung für den Erfolg des Montageergebnisses rückzuschließen. Hierfür wurde eine Fügeversuchseinrichtung konzipiert und umgesetzt. Abbildung 46 zeigt den Aufbau der Fügeversuchseinrichtung.

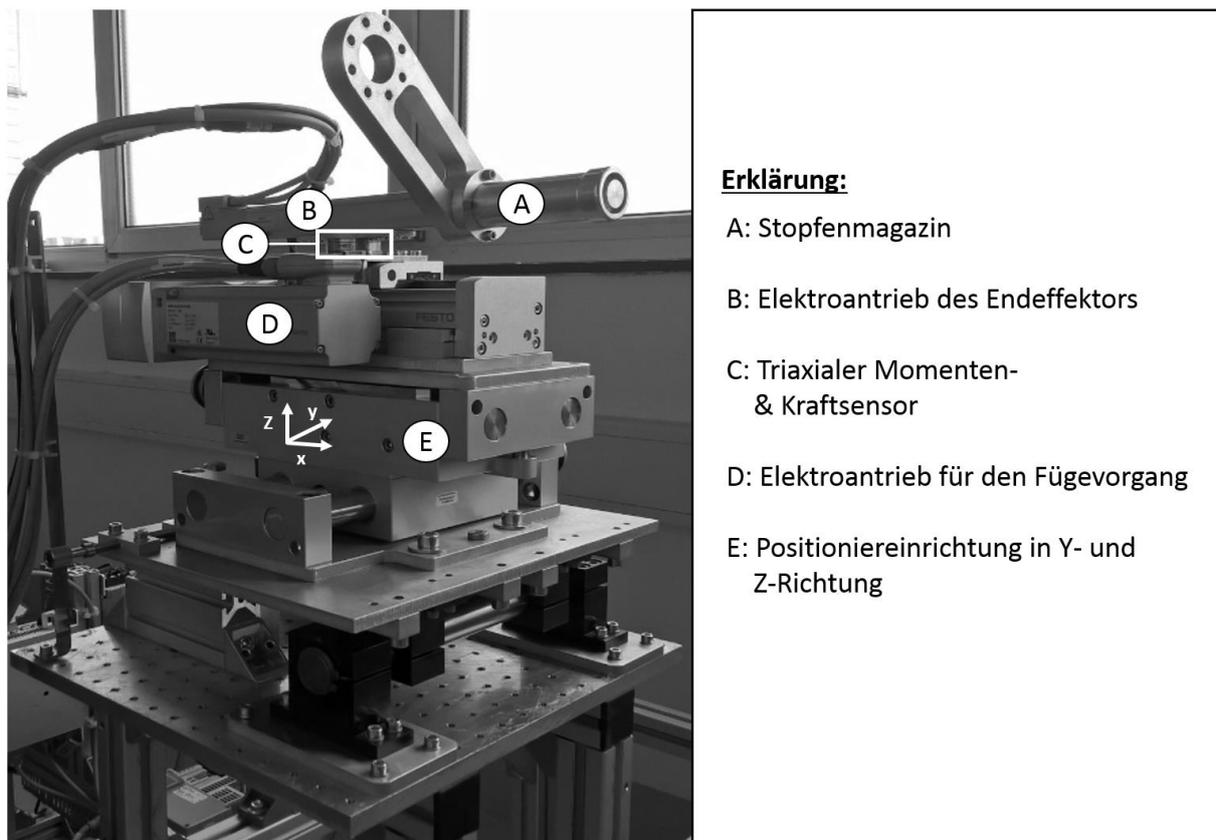


Abbildung 46: Fügeversuchseinrichtung zur Erfassung der Kraft- und Momentenverläufe über den Fügevorgang.

Für die Positionierung des Stopfens in Vorladeposition wurden das Stopfenmagazin sowie der elektrische Antrieb in identischer Art und Weise zum Serienendeffektor verwendet (vgl. Kapitel 6.2.2). Durch die Verwendung einer Zentriervorrichtung wurde die Versuchseinrichtung zentriert vor dem Loch im Karosserieblech ausgerichtet. Über einen weiteren Elektroantrieb erfolgte anschließend die Vorschubbewegung des gesamten Endeffektors in X-Richtung zur Durchführung des Fügevorgangs. Im Sockel des Endeffektors wurden die im Rahmen des Fügevorgangs auftretenden Kräfte und Momente in allen drei Dimensionen aufgezeichnet. Der verwendete Sensor hatte dafür eine Auflösung von  $1/188$  Nm mit einem

Messbereich von +/-20 Nm. Abbildung 47 zeigt ein Beispiel der erfassten Messwerte über den zeitlichen Verlauf des Fügevorgangs.

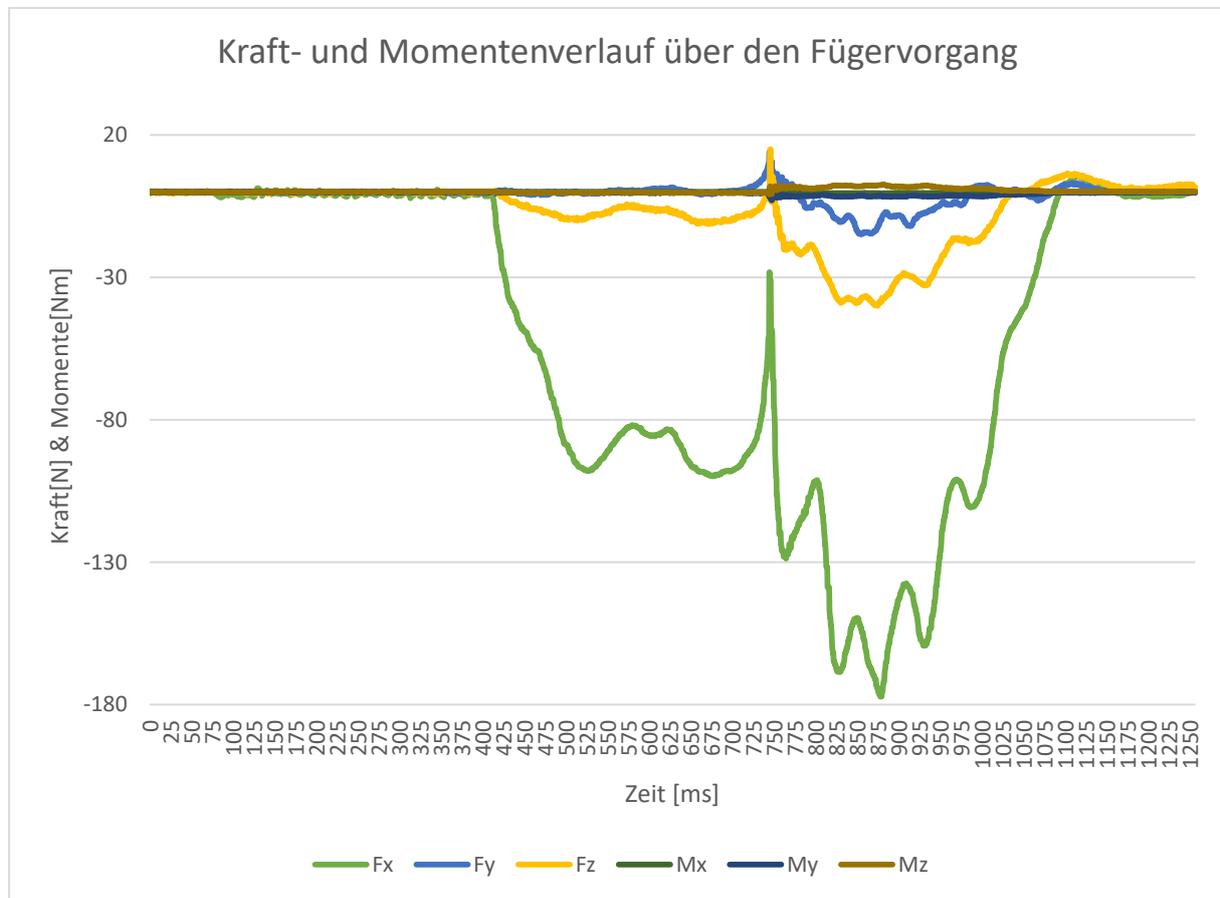


Abbildung 47: Erfasste Kraft- und Momentenverläufe eines idealtypischen Fügevorgangs.

Die dabei gemessenen auftretenden Kippmomente waren dabei über die gesamte Versuchssreihe in der Nähe von Null Nm. Erklärbar ist dieses Resultat über die spezifischen Eigenschaften der Verschlussstopfen. Da es sich dabei um ein Elastomer handelt, erfolgt keine Weitergabe auftretender Kippmomente zurück auf die Fügeversuchseinrichtung. Auftretende Momente führen stattdessen zu einer elastischen Verformung der Verschlussstopfen und sind daher nicht am Endeffektor messbar. Eine Nachvollziehbarkeit eventuell auftretender Kippmomente über den Fügevorgang scheint somit nicht möglich. Infolgedessen wurde daher die Erfassung der Vorladeposition über Bilddaten für das weitere Vorgehen der Versuchsdatenerzeugung festgelegt.

### Erfassung der Lichtstärke, Luftfeuchtigkeit und Raumtemperatur

Die Dokumentation der Lichtstärke, Luftfeuchtigkeit und Raumtemperatur erfolgt über den XDK 110-Sensor der Firma Bosch. Der Sensor ist dafür fest an der Karoserieseitenwand

und somit in unmittelbarer Nähe zum zu fügenden Loch angebracht. Die Messdatenaufnahme erfolgt kurz vor dem Montagevorgang. Die Messdaten werden über USB-Schnittstelle direkt an das zentrale Rechnersystem übermittelt.



Abbildung 48: XDK Sensor zur Erfassung der Lichtstärke und Raumtemperatur.

Die Erfassung der Lichtstärke erfolgt in ganzen Lux, die Luftfeuchtigkeit wird in ganzzahligen Prozenten gemessen. Die Erfassung der Raumtemperaturdaten erfolgt in °C mit der Genauigkeit einer Nachkommstelle.

### **Erfassung des Lochtypen**

Die betrachteten Verschlussstopfen können gemäß Spezifikation in Löchern unterschiedlicher Blechdicke verbaut werden. Die Blechdickenunterschiede in der betrachteten Karosserie-Seitenwand liegen dabei unter 0,1mm und werden in der Betrachtung nicht berücksichtigt. Neben den unterschiedlichen Blechdicken kann an der Realkarosse zwischen Rundlöchern und Kragenlöchern unterschieden werden. Abbildung 49 zeigt die schematischen Unterschiede zwischen beiden auftretenden Lochtypen. Dabei unterscheiden sich Kragenlöcher durch das Vorhandensein eines Stanzkragens am Loch. Der existierende Stanzkragen erschwert das Hinterrasten der Verschlussstopfen im Loch. Die Existenz von Stanzkragen hat ihre Ursache in der Verwendung spezifischer Werkzeuge in der Technologie Umformung der Automobilproduktion. Kragenlöcher befinden sich immer an denselben Stellen im Karosserieblech. Ein Wechsel von einem Rund- zu einem Kragenloch einer speziellen Lochposition von Karosse zu Karosse findet nicht statt. Die Information über den Lochtypen ist somit bereits vor dem Fügevorgang vorhanden. Für die Versuchsdatenerhebung wurden Rund- und Kragenlöcher in einem gleichmäßigen Verhältnis gefügt und die bekannte Information über den jeweiligen Lochtypen im Datenset abgespeichert.

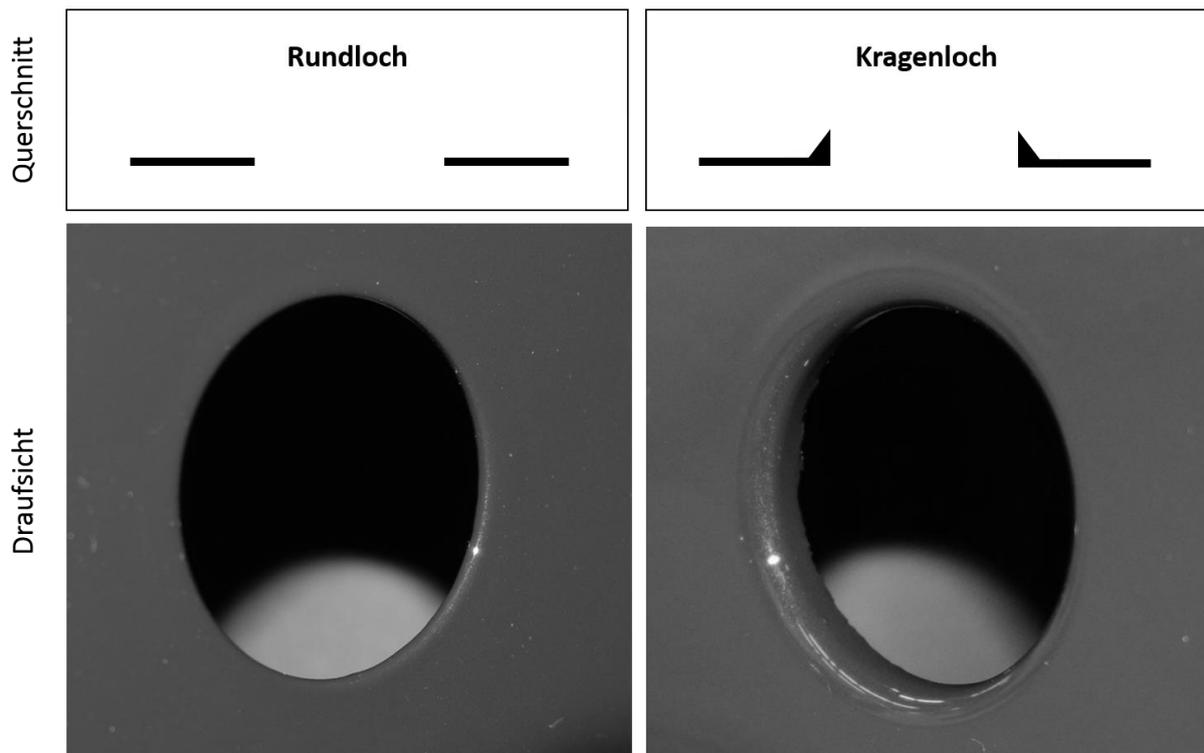


Abbildung 49. Unterscheidung Rundloch zu Kragenloch.

### Erfassung des Montageergebnisses

Nach einer jeweiligen Durchführung eines Montagevorgangs erfolgte die Auswertung des Montageergebnisses durch den Anlagenbediener. Dabei wurde unterschieden in vier mögliche Montageergebnisse:

- i. O.,
- n. i. O. nicht verrastet,
- n. i. O. scheinverrastet,
- Ungültiger Vorgang.

Das Montageergebnis wird nur dann als i. O. gewertet, wenn der Stopfen über den automatisierten Montageprozess vollständig verrastet ist. Abbildung 50 zeigt einen vollständig verrasteten sowie einen scheinverrasteten Stopfen. Über eine manuelle Andrückprobe wird weiterhin sichergestellt, dass auch ein nicht optisch wahrnehmbares Scheinverrasten berücksichtigt wird. Kann der Stopfen über manuelles Nachdrücken weiter verrastet werden, so wird das Montageergebnis als n. i. O. gewertet. Fällt der Stopfen nach dem Montagevorgang eigenständig aus dem Loch, gilt dieser als nicht verrastet. Für den etwaigen Fall der Prozessunterbrechung aufgrund von Fehlern in der Kommunikation zwischen SPS und Endeffektor wird der Vorgang als ungültig bewertet.

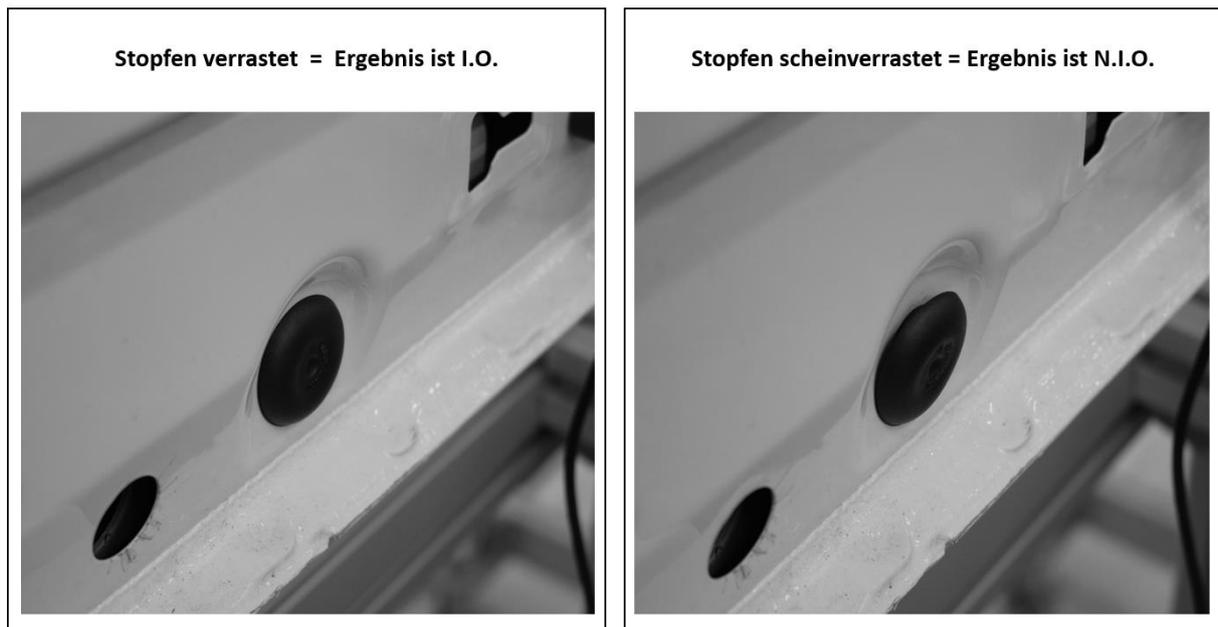


Abbildung 50: Verrastete und scheinverrastete Verschlussstopfen nach der automatisierten Montage.

Die Dokumentation erfolgte dabei über die Auswahl des entsprechenden Zustands im dafür entwickelten Interface über einen Touchscreen (vgl. Abbildung 51).

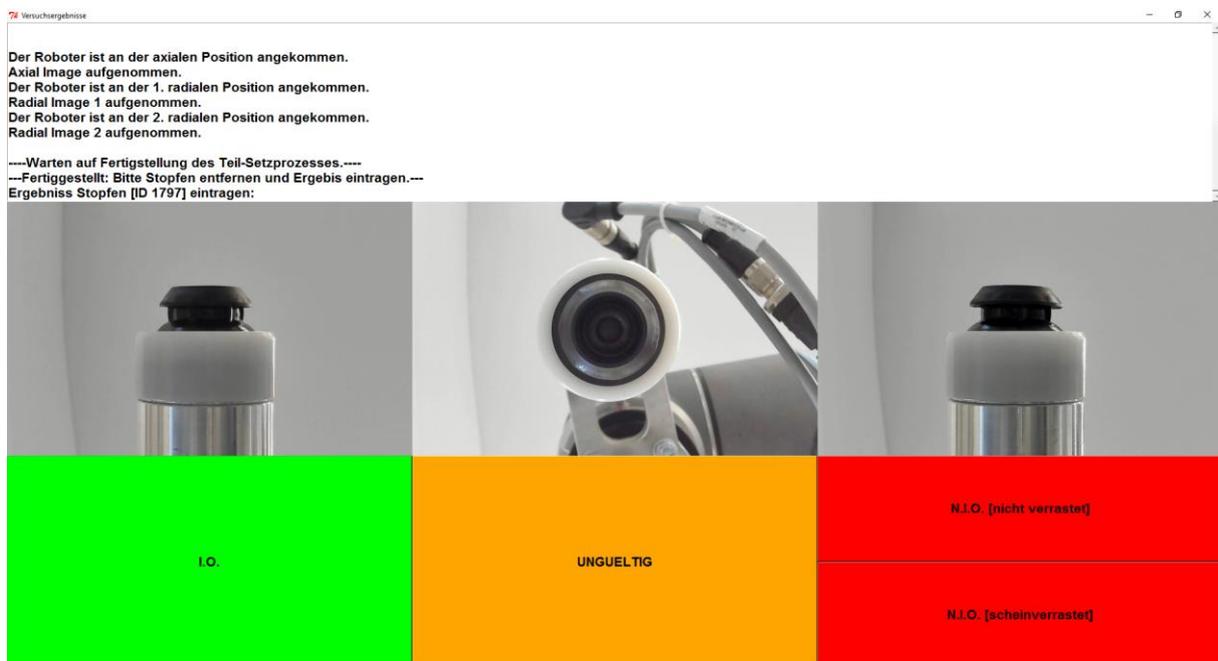


Abbildung 51: Eingabemaske zur Erfassung des jeweils erreichten Montageergebnisses.

## 6.4 Prototypische Konzeptumsetzung der Fehlervorhersage

Im vorangegangenen Kapitel 6.3 der vorliegenden Arbeit wurde die Konzeptionierung und Umsetzung einer Versuchsanlage für die Aufnahme möglichst realitätsnaher Datenmengen detailliert beschrieben. Aufbauend auf dieser Versuchsanlage und der damit erhobenen Datenmengen wurde für die prototypische Umsetzung einer fehlervorhersagenden Systemkomponente zunächst eine geeignete Entwicklungsumgebung ausgewählt und in dem in Kapitel 6.3.1 beschriebenen zentralen Rechensystem implementiert. Zur Realisierung des in Kapitel 5.2.1 beschriebenen Systementwurfs können prinzipiell eine Reihe unterschiedlicher Programmiersprachen und Entwicklungsumgebungen Anwendung finden. Eine umfassende Untersuchung existierender Programmiersprachen und Entwicklungsumgebungen würde den Betrachtungsfokus und Rahmen dieser Arbeit jedoch überschreiten. Stattdessen wurde die dem Autor dieser Arbeit bekannte und auf der Programmiersprache Python basierende Entwicklungsumgebung PyCharm ausgewählt. Die Auswahl fiel dabei auf die Programmiersprache Python, da hierfür mit scikit-learn, TensorFlow und Neurolab umfangreiche und weit etablierte Programmbibliotheken für maschinelle Lernverfahren zur Verfügung stehen.

Besonders im Umfeld maschineller Lernalgorithmen hat sich in der wissenschaftlichen Literatur die Praxis etabliert, dass die Optimierung und richtige Parametrierung der Algorithmen empirisch erfolgt (vgl. Pal und Mitra 1992, S. 685). Diese etablierte Praxis wurde daher auch als Vorgehensmodell für den Rahmen dieser Arbeit gewählt. Auch hier ist eine gesamthafte Untersuchung aller existierender Ansätze und möglicher Parametrierungen im Rahmen dieser Arbeit nicht möglich. Stattdessen wurden einige etablierte Algorithmen aus dem Bereich SVM, MLP und LVQ ausgewählt und über ein empirisches Vorgehen parametrisiert. Tabelle 3 bietet einen Überblick über den jeweils konkret ausgewählten Algorithmus und die empirisch bestimmte Parametrierung. Die Parametrierung erfolgte dabei auf Basis eines mit der Problemstellung vergleichbaren Versuchsdatensets.

Tabelle 3: Angewendete Algorithmen des Supervised Learning zur Fehlervorhersage.

Kategorie	Algorithmus	Parametrierung	Verwendete Bibliothek
SVM	SVC	C : 10; Kernel : rbf; alle anderen: default;	Scikit-learn Sklearn.svm.SVC
MLP	CNN & FCNN	learning_rate: 1e-3; batch_size: 15; training_epochs: 500; Aktivierungsfunktion: ReLu; hidden_layers (FCNN): 2; hidden_layers (CNN): 3; Neuronen je hidden layer: 200	TensorFlow
LVQ	LVQ1	Neuronen hidden Layer: 200 Pc: 50 %,50 % learning_rate: 0,01	Neurolab
LVQ	GLVQ	Squared euclidian distance learning_rate: 0,0001 maximum_iterations: 2500 Abbruch bei gtol: 1e-5	Scikit-learn - basierend auf Matlab - nach M.Biehl University of Groningen.

Die Implementierung der in Kapitel 5.2.1 als Lösungsraum identifizierten SVMs erfolgte dabei über Sklearn.svm. Wie in Kapitel 5.2.1 beschrieben bietet die Anwendung sogenannter Soft-Margin SVMs vor allem bei nicht linear trennbaren Klassifizierungsproblemen Vorteile. Aus der Reihe möglicher SVMs dieser Form wurde die C-Support Vector-Klassifizierung ausgewählt und gemäß Tabelle 3 parametriert. Der Parameter C beeinflusst dabei die Bestrafung einer möglichen Fehlklassifizierung durch den Algorithmus.

Die Anwendung von MLP bietet über eine mögliche Kombination von MLP-Schichten mit einem Convolution Neural Network eine Möglichkeit der impliziten Datenvorverarbeitung innerhalb des Algorithmus. Bei der Anwendung von MLP erfolgte dafür eine Kombination aus einem CNN und einem Fully Connected Multilayer Perceptron-Netzwerk unter Verwendung der Bibliothek TensorFlow. Die Aufgabe des CNN ist dabei die implizite Vorverarbeitung der Bilddaten über 3 convolutional layer (vgl. Kapitel 5.3.1). Das CNN reduziert die 360\*360\*3-Pixeldaten in Summe somit von 388800 numerischen Werten auf 64800 nu-

merische Zahlenwerte, welche dem FCNN zusammen mit den 7 übrigen externen Einflussvariablen des Merkmalsdatenvektors (vgl. Kapitel 6.3.2) übergeben werden. Die Identifikation der gewählten Parametrierung erfolgt dabei wie beschrieben empirisch über eine Auswahl unterschiedlich möglicher Parametrierungen.

Die Implementierung prototypenbasierter Lernmodelle der Learning Vector Quantization erfolgt über insgesamt 2 Algorithmen. Zum einen wurde LVQ1 gemäß Neurolab implementiert, sowie die erweiterte LVQ Variante GLVQ. Für Letztere wurde die auf Matlab basierende GLVQ-Implementation für Scikit-learn verwendet. Es wurden beide Algorithmen erprobt, da GLVQ Vorteile hinsichtlich seiner Generalisierungsfähigkeit und Konvergenzeigenschaften bietet, LVQ1 jedoch in verschiedenen Anwendungen nichtsdestotrotz die besseren Ergebnisse gegenüber GLVQ und anderen Varianten erbracht hat (vgl. Ghosh et al. 2006, S. 817).

#### 6.4.1 Betrachteter Merkmalsdatenvektor und Datenvorverarbeitung

In Kapitel 6.3.2 wurde der für den gewählten Beispielprozess identifizierte und in den Versuchsdaten erfasste Merkmalsdatenvektor beschrieben. Abbildung 52 gibt einen Überblick über den betrachteten Merkmalsdatenvektor und den notwendigen Schritt der Datenvorverarbeitung. Aufgrund der unterschiedlichen Intervallgröße der real auftretenden Einflussvariablen könnte eine direkte Datenverarbeitung zu einem potentielle verfälschten Verhalten der Lernstruktur führen. Um diesen Effekt zu vermeiden ist zur Datenverarbeitung zunächst eine einheitliche Skalierung der betrachteten Einflussvariablen notwendig. Im konkreten Anwendungsfall dieser Arbeit wurden daher alle Messwerte einer jeden Einflussvariable zunächst in das Wertebereich  $[0,1]$  skaliert. Über die angewendete Skalierung wird dabei das Werteverhältnis innerhalb der auftretenden Größen einer Einflussvariable erhalten, die Beeinflussung des Lernens des ausgewählten Algorithmus über Schwankungen einer Einflussvariable aber ins Verhältnis zur Größe des gemessenen Datenintervalls gesetzt. Es wären an dieser Stelle grundsätzlich auch andere Skalierungsverfahren denkbar. Für die Anwendung neuronaler Netze hat sich in der wissenschaftlichen Praxis neben der beschriebenen Skalierung in das Wertebereich  $[0,1]$  insbesondere eine z-Transformation auf eine Standardnormalverteilung mit Mittelwert 0 und einer Standardabweichung von 1 etabliert. Grundsätzlich ist dabei festzuhalten, dass die Wahl einer passenden Datenvorskalierung stark von der gewählten Aktivierungsfunktion abhängig ist. Im Falle der nullsymmetrischen sigmoid Aktivierungsfunktion kann eine Skalierung in das Wertebereich  $[0,1]$  zu

einer erhöhten Störanfälligkeit der verwendeten Netzstruktur führen (vgl. LeCun et al. 2012). Für die hier gewählte ReLu Aktivierungsfunktion scheint dieser Umstand aufgrund der nicht nullsymmetrischen Eigenschaften der ReLu Funktion im aktuellen wissenschaftlichen Stand weniger bekannt. Weiterhin ist eine  $[0,1]$ -Skalierung der Pixelwerte zur Verarbeitung im CNN eine etablierte Praxis. Im Sinne einer einheitlichen Datenskalierung wurde diese Form der Datennormalisierung daher gesamthaft angewendet. Zur Bestätigung dieser Annahmen findet sich ein Vergleich der erreichten Vorhersageergebnisse mittels dieser gewählten Skalierung zu den Vorhersageergebnissen unter Verwendung der beschriebenen z-Transformation im Anhang dieser Arbeit.

Weiterhin muss an dieser Stelle jedoch festgehalten werden, dass eine generelle Verbesserung der Systemeigenschaften hinsichtlich Präzision, Robustheit, etc. über die Auswahl einer anderen Datenvorskalierung grundsätzlich denkbar ist. Die Auswahl einer möglichst optimalen Datenskalierung sowie die Parametrierung der ausgewählten algorithmischen Lösungsansätze liegt jedoch nicht im vorwiegenden wissenschaftlichen Betrachtungsfokus dieser Arbeit sondern vielmehr die generelle Entwicklung und Bestätigung eines Konzeptes zur selbstlernenden Fehlervermeidung automatisierter Montagesysteme im Anlauf der Fahrzeugproduktion.

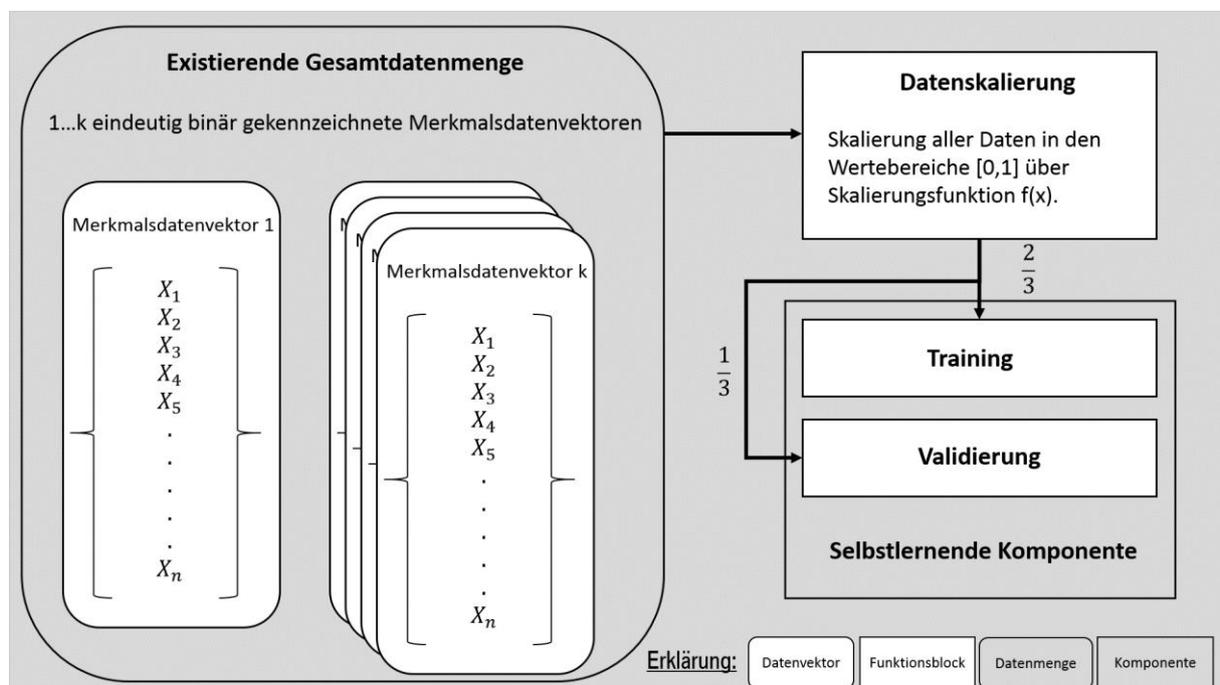


Abbildung 52: Datenskalierung als notwendiger Schritt der Datenvorverarbeitung.

Der erhobene Merkmalsdatenvektor (vgl. Kapitel 6.3.2) kann weiterhin unterteilt werden in die fünf physikalischen Messgrößen: erfasste Stopfenhärte, erfasste Oberflächentemperatur des Stopfens, erfasste Raumtemperatur, erfasste Luftfeuchtigkeit und erfasste Lichtstärke. Die weiteren Messgrößen sind die im Vorhinein zu jedem Montagevorgang bekannte Einflussvariable Lochtyp und die über die Bildverarbeitung aus 3 Betrachtungswinkeln erfasste Vorladeposition des Stopfens. Dabei ist jeder Merkmalsdatenvektor pro ausgeführtem Montagevorgang eindeutig binär über das damit erreichte Montageergebnis i. O. bzw. n. i. O. gekennzeichnet. Die erfasste Vorladeposition unterscheidet sich hierbei jedoch grundlegend von den anderen Einflussvariablen, da diese nicht über einen einzelnen numerischen Zahlenwert erfasst wird, sondern im konkreten Fall eine Dimension von  $360 \times 360$  Pixeln  $\times 3$  RGB-Werten entspricht. Die Gesamtdimension der erfassten Vorladeposition umfasst somit 388800 Zahlenwerte. Eine eventuell sinnvolle Sonderbehandlung dieser Einflussvariablen wird daher im Rahmen der prototypischen Umsetzung näher untersucht.

#### 6.4.2 Unterteilung der Gesamtdatenmenge und weitere Vorbetrachtungen

Zur prototypischen Umsetzung der fehlervorhersagenden Teilkomponente des Gesamtsystems wurde ein Gesamtdatenset von 2000 Montagevorgängen erhoben. Jeder Montagevorgang ist dabei über einen Merkmalsvektor von 388807 skalierbaren numerischen Messgrößen und einer klaren binären Kennzeichnung definiert.

Tabelle 4 zeigt die Korrelationsmatrix über alle initial identifizierten Einflussvariablen mit Ausnahme der Stopfenvorladeposition. Hieraus ist gut ersichtlich, dass für keine der identifizierten Einflussvariablen ein vollständig linearer Zusammenhang existiert, auch wenn ein starker negativer Zusammenhang zwischen Stopfenhärte und Oberflächentemperatur des Stopfens abgeleitet werden kann. Weiterhin kann mit Hilfe der Korrelationsmatrix ein zumindest schwach linearer Zusammenhang jeder aufgenommenen Einflussvariable auf das Montageergebnis gezeigt werden. Die in Kapitel 6.2.5 durchgeführte Analyse zur Ableitung relevanter Einflussvariablen auf das Montageergebnis kann somit an dieser Stelle grundsätzlich bestätigt werden und keine der aufgenommenen Einflussvariablen für die weitere Datenverarbeitung grundlegend ausgeschlossen werden.

Weiterhin zeigt die Korrelationsmatrix des ausgewählten realen Prozesses erneut eine Herausforderung für rein menschliche Optimierungsprozesse. Im ausgewählten Fall ist aufgrund der Korrelationsmatrix kein eindeutiger Zusammenhang zwischen den möglichen

Einflussvariablen und dem erreichten Montageergebnis ableitbar. Eine menschliche Optimierung anhand der Erkenntnisse ist somit aufgrund der existierenden Gesamtkomplexität nur schwer möglich.

Tabelle 4. Korrelationsmatrix der identifizierten Einflussvariablen (ohne Stopfenvorladeposition).

	Lochtyp	Stopfenhärte	Oberflächentemperatur Stopfen	Raumtemperatur	Luftfeuchtigkeit	Lichtstärke	Montageergebnis
Lochtyp	1,000	-0,003	0,019	0,005	-0,012	0,008	0,143
Stopfenhärte	-0,003	1,000	-0,789	-0,078	0,099	-0,229	0,250
Oberflächentemperatur Stopfen	0,019	-0,789	1,000	0,310	-0,310	0,240	-0,337
Raumtemperatur	0,005	-0,078	0,310	1,000	-0,324	0,510	-0,295
Luftfeuchtigkeit	-0,012	0,099	-0,310	-0,324	1,000	-0,132	0,305
Lichtstärke	0,008	-0,229	0,240	0,510	-0,132	1,000	-0,186
Montageergebnis	0,143	0,250	-0,337	-0,295	0,305	-0,186	1,000

### Exkurs Lichtstärke als Einflussgröße:

Ein Einfluss der vorherrschenden Lichtstärke auf das zu erwartende Montageergebnis ist dabei nicht unbedingt intuitiv. Tabelle 4 zeigt lediglich eine schwache negative Korrelation zwischen der vorherrschenden Lichtstärke und dem Montageergebnis, welche absolut jedoch vergleichbar ist mit der Korrelation von Lochtyp und Montageergebnis. Der Einfluss des Lochtypen wurde in Vorbetrachtungen als besonders relevant empfunden und in der in Kapitel 6.2.5 durchgeführten Analyse als relevant identifiziert. Um somit an dieser Stelle keinen unbekanntem physikalischen Zusammenhang zwischen Lichtstärke und Montageergebnis auszuschließen, wird für den weiteren Verlauf dieser Arbeit die Einflussgröße Lichtstärke weiterhin berücksichtigt.

Aufgrund der vielfältigen und physikalisch nur aufwendig beschreibbaren Zusammenhänge zwischen den Einflussvariablen untereinander sowie auf das Montageergebnis bestä-

tigt sich hier erneut die Zielsetzung eines selbstlernenden Montagesystems im Produktionsanlauf sowie die Auswahl eines Klassifikators, welcher gut mit einer hohen Datenkomplexität umgehen kann.

Die zur Verfügung stehende Datenmenge wurde in einem nächsten Schritt in eine Trainings- und Validierungsdatenmenge unterteilt (vgl. Abbildung 52). Über die Anwendung einer diskreten gleich verteilten Wahrscheinlichkeitsfunktion (`numpy.random.randint`) wurde ein Validierungsdatenset von 30 % der Gesamtdatenmenge extrahiert und die übrigen 70 %, im konkreten Fall also 1400 binär gekennzeichnete Datensets, für das Training der maschinellen Lernalgorithmen verwendet.

## 6.5 Ergebnisse der umgesetzten Fehlervorhersage

### 6.5.1 Reduzierung des Merkmalsdatenvektors

Die beschriebene entwickelte Gesamtsystemarchitektur eines selbstlernenden automatisierten Montagesystems berücksichtigt die Vorverarbeitung hochdimensional erfasster Einflussvariablen über eine Datenvorverarbeitung (vgl. Abbildung 29, S. 83). Durch die Anwendung unterschiedlicher Methoden und mathematischer Ansätze entsteht dabei ein aggregierter Merkmalsdatenvektor, welcher von einer selbstlernenden Komponente für die Fehlervorhersage verwendet wird. In Kapitel 5.3 wurden dafür bereits unterschiedliche mögliche Ansätze und Methoden identifiziert und beschrieben. In der prototypischen Umsetzung wird der Ansatz über eine Datenvorverarbeitung im CNN für MLP, die Merkmalsdatenreduktion über Expertenwissen sowie die Hauptkomponentenanalyse PCA realisiert und deren Einfluss auf den Leistungsvergleich der identifizierten selbstlernenden Algorithmen betrachtet. Der beschriebene Ansatz einer Dimensionsreduzierung hochdimensional erfasster Einflussvariablen erfolgt dabei anhand der Einflussvariable „Vorladeposition des Stopfens“ für den beschriebenen Beispielsprozess der automatisierten Stopfenmontage. Gemäß Kapitel 6.3.2 wird diese Einflussvariable hochdimensional über ein Bild mit 360x360 Pixeln erfasst. Für jeden Pixel ergeben sich daraus 3 RGB-Werte und damit eine Gesamtdimension von 388800 numerischen Zahlenwerten pro aufgenommener Vorladeposition.

### **Reduzierung der Dimensionalität über CNN**

Die Anwendung von Convolutional Neural Networks bietet eine Möglichkeit der impliziten Dimensionsreduzierung für den gewählten Ansatz eines MLP im Rahmen der Gesamtarchitektur des erzeugten neuronalen Netzes. Das CNN besitzt dafür 3 convolutional layer und einen flattening layer und reduziert die Gesamtdimension von 388800 Zahlenwerten für die Vorladeposition auf 64800 numerische Zahlenwerte zur Weiterverarbeitung mit den übrigen erfassten Einflussvariablen im MLP. Da es sich bei CNN um eine zu MLPs grundsätzlich ähnliche Architektur handelt, welche zu einem Gesamtnetz vereint werden können, erfolgt diese Form der Datenvorverarbeitung explizit nur für die algorithmische Lösung eines MLP-Netzes.

### **Reduzierung der Dimensionalität über PCA**

Die Implementierung der Hauptkomponentenanalyse für die beschriebene hochdimensionale Einflussvariable erfolgte über die in der Bibliothek scikit-learn zur Verfügung stehende Methode `sklearn.decomposition.PCA`. Über die ersten 1000 Hauptkomponenten wurden dabei 99 % der Daten vollständig beschrieben. Die daraus entstehenden 1000 numerischen Zahlenwerte wurden gemäß dem in 6.4.1 beschriebenen Vorgehen ebenfalls skaliert und in allen identifizierten Algorithmen (SVC, MLP, LVQ1 und GLVQ) für die Fehlervorhersage verwendet.

### **Reduzierung der Dimensionalität über Expertenwissen**

Für die Dimensionsreduzierung über Expertenwissen erfolgte zunächst in einem eintägigen Expertenworkshop die Identifikation der nach Expertenmeinung relevanten Bildinformationen für den Erfolg des Montagevorgangs. Insgesamt waren 5 Experten aus dem Umfeld der innovativen Automatisierung beteiligt. Die Anforderungen an einen Experten waren hierbei dieselben wie für die Durchführung des in Kapitel 6.2.5 beschriebenen Expertenworkshops. Als Ergebnis des Workshops konnte dabei einstimmig die Höhe der Positionierung des Stopfens aus dem Tool heraus sowie die Genauigkeit der Zentrierung des Stopfens in Vorladeposition identifiziert werden. Die messtechnische Auswertung der identifizierten Kriterien aus den Bilddaten erfolgte dabei mittels der für Python zur Verfügung stehenden freien Programmbibliothek OpenCV. Hierfür wurde aus den in den Perspektiven A und B (vgl. Kapitel 6.3.2) aufgenommenen Bildern jeweils die Steigung der Stopfenvorderkante aus Seitensicht sowie ein fest definierter Punkt der Stopfenkontur ausgewertet. Für jede aufgenommene Vorladeposition des Stopfens ergab sich damit ein ebenfalls in das

Intervall  $[0,1]$  skalierbarer Merkmalsvektor von 6 numerischen Zahlenwerten bestehend aus zwei Steigungswerten sowie zwei Positionswerten im 2-dimensionalen Bild. Abbildung 53 zeigt eine beispielhafte Auswertung zweier unterschiedlicher Vorladepositionen über das beschriebene Vorgehen.



Abbildung 53: Über Expertenwissen extrahierte "relevante" Bildfeatures.

### 6.5.2 Leistungsvergleich der identifizierten Ansätze

In einem nächsten Schritt erfolgte der Leistungsvergleich der in Kapitel 6.4 beschriebenen und entsprechend parametrisierten Algorithmen. Die Erprobung der Algorithmen wurde dabei auf insgesamt vier möglichen Merkmalsdatenvektoren pro Einzelelement der Gesamtdatenmenge ausgeführt. Dabei wurde unterschieden in die Datenmengen:

- Sensor- und Bilddaten,
- Sensordaten und Bildmerkmale,
- Sensordaten,
- Sensordaten und PCA.

Innerhalb einer jeden Datenmenge ist zusätzlich ein jeder Merkmalsdatenvektor eindeutig binär über das damit erreichte Montageergebnis in i. O. bzw. n. i. O. gekennzeichnet.

#### **Sensor- und Bilddaten**

Der Merkmalsdatenvektor der Sensor- und Bilddaten umfasst alle in Kapitel 6.4.1 beschriebenen und entsprechend skalierten 388807 numerischen Zahlenwerte. Berücksichtigt werden damit alle fünf physikalischen Messgrößen bestehend aus der erfassten Stopfenhärte, der erfassten Oberflächentemperatur des Stopfens, der erfassten Raumtemperatur, der erfassten Luftfeuchtigkeit und der erfassten Lichtstärke. Sowie die im Vorhinein zu jedem Montagevorgang bekannte Einflussvariable Lochtyp, die über die Bildverarbeitung erfass-

ten 388800 RGB-Pixelwerte für die Vorladeposition des Stopfens und das erzielte Montageergebnis. Abbildung 54 gibt einen Überblick über den beschriebenen Merkmalsdatenvektor.

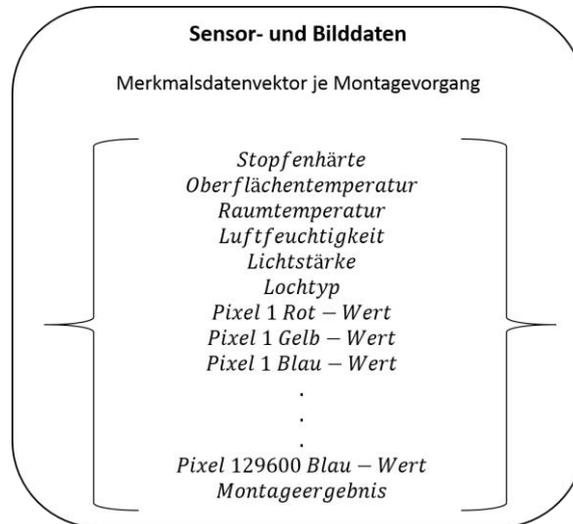


Abbildung 54: Merkmalsdatenvektor Sensor- und Bilddaten.

### Sensordaten und Bildmerkmale

Der hierunter erfasste Merkmalsdatenvektor gleicht im Wesentlichen dem unter Sensor- und Bilddaten beschriebenen Umfang, mit Ausnahme der Erfassung der Einflussvariable Vorladeposition des Stopfens. Anstelle der 388800 RGB-Pixelwerte sind hierfür die über Expertenwissen identifizierten 6 Merkmalswerte je Vorladeposition erfasst (vgl. Kapitel 6.5.1, S. 114). Die Gesamtdimension des Merkmalsdatenvektors entspricht daher insgesamt 13 skalierten numerischen Zahlenwerten (vgl. Abbildung 55).

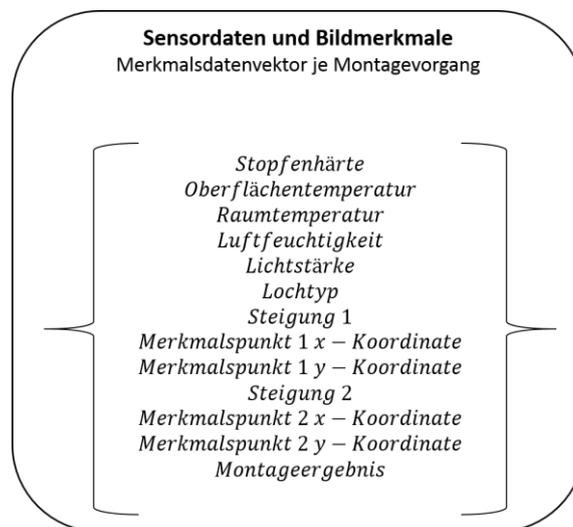


Abbildung 55: Merkmalsdatenvektor Sensordaten und Bildmerkmale.

## Sensordaten

Dieser Merkmalsdatenvektor berücksichtigt alle beschriebenen fünf physikalischen Messgrößen, die Einflussvariable Lochtyp und das binäre Ergebnis des Montageprozesses. Die Gesamtdimension beträgt damit 7 Zahlenwerte (vgl. Abbildung 56). Die Einflussvariable Vorladeposition des Stopfens wird nicht berücksichtigt.

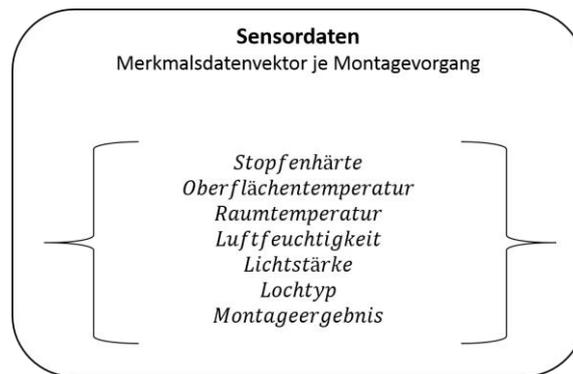


Abbildung 56: Merkmalsdatenvektor Sensordaten.

## Sensordaten und PCA

Der dadurch beschriebene Merkmalsdatenvektor gleicht dem Merkmalsdatenvektor Sensor- und Bildmerkmale mit einer Ausnahme. Im konkreten Fall findet die Dimensionsreduzierung der Bilddaten über die in Kapitel 5.3.1 und 6.5.1 beschriebene Hauptkomponentenanalyse statt. Die Gesamtdimension des Merkmalsdatenvektors beträgt daher 1007 skalierte numerische Zahlenwerte (vgl. Abbildung 57).

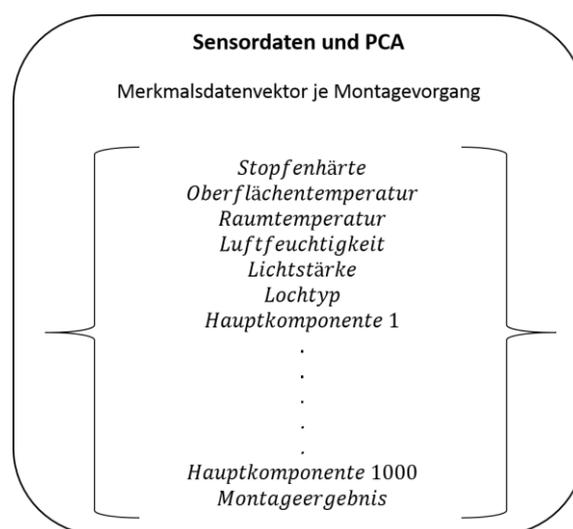


Abbildung 57: Merkmalsdatenvektor Sensordaten und PCA.

MLP (CNN+FCNN) mit Sensor- und Bilddaten

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	213	74	287
Vorhersage I.O.	60	253	313
Summe	273	327	600

MLP (FCNN) mit Sensordaten

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	170	71	241
Vorhersage I.O.	103	256	359
Summe	273	327	600

MLP (FCNN) mit Sensordaten und Bildmerkmalen

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	185	55	240
Vorhersage I.O.	88	272	360
Summe	273	327	600

MLP (FCNN) mit Sensordaten und PCA

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	206	83	289
Vorhersage I.O.	67	244	311
Summe	273	327	600

LVQ1 mit Sensor- und Bilddaten

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	3	2	5
Vorhersage I.O.	270	325	595
Summe	273	327	600

LVQ1 mit Sensordaten

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	105	26	131
Vorhersage I.O.	168	301	469
Summe	273	327	600

LVQ1 mit Sensordaten und Bildmerkmalen

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	98	24	122
Vorhersage I.O.	175	303	478
Summe	273	327	600

LVQ1 mit Sensordaten und PCA

	N.I.O.	I.O.	Summe
Vorhersage N.I.O.	101	27	128
Vorhersage I.O.	172	300	472
Summe	273	327	600

Abbildung 58: Konfusionsmatrizen MLP und LVQ1 über 600 Validierungsdaten bei unterschiedlicher Zusammensetzung der betrachteten Merkmalsvektoren.

GLVQ mit Sensor- und Bilddaten

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	147	95	242
Vorhersage I.O.	126	232	358
Summe	273	327	600

GLVQ mit Sensordaten

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	142	50	192
Vorhersage I.O.	131	277	408
Summe	273	327	600

GLVQ mit Sensordaten und Bildmerkmalen

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	76	13	89
Vorhersage I.O.	197	314	511
Summe	273	327	600

GLVQ mit Sensordaten und PCA

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	82	8	90
Vorhersage I.O.	191	319	510
Summe	273	327	600

SVC mit Sensor- und Bilddaten

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	203	70	273
Vorhersage I.O.	70	257	327
Summe	273	327	600

SVC mit Sensordaten

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	145	61	206
Vorhersage I.O.	128	266	394
Summe	273	327	600

SVC mit Sensordaten und Bildmerkmalen

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	181	63	244
Vorhersage I.O.	92	264	356
Summe	273	327	600

SVC mit Sensordaten und PCA

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	197	36	233
Vorhersage I.O.	76	291	367
Summe	273	327	600

Abbildung 59: Konfusionsmatrizen GLVQ und SVC über 600 Validierungsdaten bei unterschiedlicher Zusammensetzung der betrachteten Merkmalsvektoren.

Abbildung 58 und Abbildung 59 zeigen die Konfusionsmatrizen der unterschiedlichen beschriebenen binären Klassifikatoren für die verschiedenen zuvor erklärten möglichen Zusammensetzungen der betrachteten Merkmalsdatenvektoren.

Im Falle des Merkmalsdatenvektors bestehend aus Sensor- und Bilddaten erfolgt für den MLP-Algorithmus eine implizite und in Kapitel 6.5.1 beschriebene Vorverarbeitung über das CNN im Rahmen eines Gesamtnetzes. In allen anderen Fällen erfolgt eine direkte Verarbeitung der skalierten Trainings- und Validierungsdaten über die im Vorfeld beschriebenen und entsprechend parametrisierten Algorithmen.

Gemäß Kapitel 6.4.2 wurde das Gesamtdatenset in 1400 Trainingsdaten und 600 Validierungs-/Testdaten unterteilt. Die ausgewählten Lernalgorithmen wurden anschließend über die gesamten Trainingsdaten trainiert und in einem nächsten Schritt der Leistungsvergleich anhand der 600 dem Algorithmus bis dahin unbekanntem Validierungsdaten durchgeführt. Zur Erzeugung einer realen Vergleichbarkeit wurde dabei für alle möglichen Fälle immer die exakt identische Unterteilung in Trainings- und Validierungsdaten beibehalten.

Die in Abbildung 58 und Abbildung 59 gezeigten Konfusionsmatrizen beschreiben die tatsächlichen Häufigkeiten sowie die durch den Klassifikator ermittelten Häufigkeiten der auftretenden Klassen zueinander und erlauben damit einen guten Vergleich der ausgewählten Klassifikatoren. Anhand der Konfusionsmatrizen können unterschiedliche Kennzahlen zur vergleichenden Beurteilung der Klassifikatoren berechnet werden. Tabelle 5 und Tabelle 6 zeigen einige aus den Konfusionsmatrizen ableitbare Kennzahlen, welche für einen direkten Leistungsvergleich der binären Klassifikatoren verwendet werden können. Zur Einhaltung der gängigen Definition und Nomenklatur der etablierten Kennzahlen entspricht eine positive Vorhersage im gewählten Montageszenario der Vorhersage eines n. i. O. und somit einer Fehlervorhersage.

Die Sensitivität beschreibt den Anteil der tatsächlich positiven Fälle, welche positiv vorhergesagt werden (vgl. Powers 2011, S. 38). Im konkreten Anwendungsfall entspricht dies dem Anteil der korrekt als n. i. O. klassifizierten Datenpunkte an der Gesamtheit der tatsächlichen n. i. O.-Datenpunkte.

Die Kennzahl Spezifität beschreibt den Anteil der tatsächlich negativen Fälle, welche negativ vorhergesagt werden. Weitere Kennzahlen sind die Relevanz, welche den Anteil tatsächlicher positiver Fälle zur Gesamtheit positiv vorhergesagter Fälle beschreibt, sowie die Segreganz, die den Anteil tatsächlicher negativer Fälle zur Gesamtheit der negativ vorhergesagten Fälle bezeichnet. (vgl. Powers 2011, S. 38–39)

Neben diesen beschriebenen Kennzahlen existieren noch weitere etablierte Kennzahlen, welche für den Leistungsvergleich binärer Klassifikatoren hilfreich sein können. Aufgrund

der gegenseitigen Beeinflussung der beschriebenen Kennzahlen ist eine unabhängige Optimierung aller Kennzahlen jedoch nicht möglich. Die Auswahl der für den Leistungsvergleich bestimmenden Kennzahlen hängt dabei zudem stark vom konkreten Anwendungsfall und der damit verfolgten Zielsetzung der Klassifizierung zusammen. Vor dem Hintergrund der Gesamtzielsetzung dieser Arbeit und der in Kapitel 5 beschriebenen entwickelten Systemarchitektur zur selbstlernenden Fehlervermeidung automatisierter Montageanlagen im Produktionsanlauf ist es nachvollziehbar, dass eine Hauptzielsetzung der erprobten Klassifikatoren in der korrekten Vorhersage der tatsächlich auftretenden n. i. O.-Montageergebnisse liegt, welche über die Kennzahl Sensitivität beschrieben wird. Eine reine Berücksichtigung der Sensitivität für die Auswahl des am besten geeigneten Klassifikators würde ihrerseits jedoch auch Algorithmen bevorzugen, welche eine hohe Sensitivität aufgrund einer sehr häufig stattfindenden fehlerhaften n. i. O.-Prognose erreichen. Im Falle eines solchen Algorithmus würden somit viele i. O.-Datenpunkte fälschlicherweise als n. i. O. vorhergesagt und im konkreten Anwendungsfall würde eine unnötige Gegenmaßnahme ausgelöst. Ein derartiges Verhalten bringt gleich mehrere Probleme mit sich: Auf der einen Seite ist eine zu häufige Gegenmaßnahme selten wünschenswert, sonst könnte diese generell präventiv für einen jeden Montagevorgang eingeleitet werden. Beispiele hierfür sind kurzzeitig tolerierbare Überlastungen in auftretenden Gelenkkraften eines Roboters, aber auch Gegenmaßnahmen, die eine geringe Taktzeiterhöhung bewirken. Weiterhin ist im Rahmen der in Kapitel 5 beschriebenen Gesamtsystemarchitektur eine selbstlernende Auswahl der bestmöglichen Gegenmaßnahme für einen gegebenen Systemzustand nur dann möglich, wenn ein Rückschluss zwischen einem tatsächlich vermiedenen Fehler und einer Gegenmaßnahme stattfinden kann. Eine hohe Rate fälschlicher n. i. O.-Prognosen würde dies jedoch verhindern.

Für den Leistungsvergleich bietet es sich somit an, sowohl die Sensitivität aber auch die Rate falscher n. i. O.-Prognosen zu berücksichtigen. Eine Möglichkeit dies zu tun besteht in der Berücksichtigung der Relevanz zusätzlich zur Sensitivität. Im Falle häufiger n. i. O.-Prognosen wäre zwar die Sensitivität hoch, die Rate der korrekt als n. i. O. klassifizierten Datenpunkte aus der Gesamtheit aller n. i. O.-Prognosen jedoch gering.

Eine Möglichkeit zur Berücksichtigung dieses Zusammenhangs besteht in der Berechnung des harmonischen Mittels aus Relevanz und Sensitivität, welches über das F-Maß beschrieben werden kann (vgl. Dembczynski et al. 2013, S. 1131).

$$F_{\beta} = \frac{(1 + \beta^2) \times (\text{Relevanz} \times \text{Sensitivität})}{\beta^2 \times \text{Relevanz} + \text{Sensitivität}} \quad (6.1)$$

Der positive Parameter  $\beta$  beschreibt dabei die Gewichtung zwischen Relevanz und Sensitivität. Ist  $\beta$  gleich 1 beschreibt das resultierende F-Maß das harmonische Mittel aus Relevanz und Sensitivität. Das F-2-Maß mit  $\beta$  gleich 2 gewichtet die Sensitivität 4-mal so hoch und das F-0,5-Maß die Relevanz 4-mal höher als die Sensitivität. Neben der gleichgewichteten Behandlung von Relevanz und Sensitivität ergibt sich über das F-Maß die Möglichkeit, ein gewichtetes harmonisches Mittel für den Leistungsvergleich der Klassifikatoren heranzuziehen. Dies ist häufig dann sinnvoll wenn im Falle gekennzeichneten Daten eine Kennzeichnung von höherer Bedeutung ist als eine andere Kennzeichnung. Im beschriebenen Anwendungsfall ist gut argumentierbar, dass eine solche unterschiedliche Bedeutung gegeben ist. Zwar ist eine hohe Anzahl falscher n. i. O.-Prognosen nicht unproblematisch, da diese wie beschrieben unnötig häufige Gegenmaßnahmen auslösen und damit zudem das Lernen der korrekten Gegenmaßnahme erschweren. Nichtsdestotrotz ist unter Berücksichtigung der Gesamtzielsetzung dieser Arbeit ein fälschlicherweise als i. O. prognostizierter n. i. O.-Datenpunkt jedoch um ein Vielfaches problematischer, da dieser direkt zu einem Fehler im Montageergebnis führt und entsprechende Nacharbeitsumfänge notwendig werden. Vor dem Hintergrund der Zielsetzung einer selbstlernenden Fehlervermeidung im Produktionsanlauf ist daher eine stärkere Gewichtung der Sensitivität gegenüber der Relevanz nachvollziehbar. Es wird daher das F-2-Maß aus den vorliegenden Kontingenztmatrizen berechnet und als entscheidende Kennzahl für den direkten Leistungsvergleich der Klassifikatoren herangezogen. Tabelle 5 und Tabelle 6 zeigen die aus den Kontingenztmatrizen abgeleiteten und vorab beschriebenen Kennzahlen.

Tabelle 5: Beschreibung der aus den Kontingenztmatrizen abgeleiteten Kennzahlen für die Beurteilung der Klassifikatoren.

Spezifität	Anteil der korrekt als i. O. klassifizierten Datenpunkte an der Gesamtheit der tatsächlichen i. O.-Datenpunkte.
Sensitivität	Anteil der korrekt als n. i. O. klassifizierten Datenpunkte an der Gesamtheit der tatsächlichen n. i. O.-Datenpunkte.
Relevanz	Anteil der korrekt als n. i. O. klassifizierten Datenpunkte an der Gesamtheit der als n. i. O. klassifizierten Datenpunkte.
Segreganz	Anteil der korrekt als i. O. klassifizierten Datenpunkte an der Gesamtheit der als i. O. klassifizierten Datenpunkte.

Klassifikationsrate	Anteil der Datenpunkte, die korrekt klassifiziert wurden.
F-Maß	Harmonisches Mittel aus Relevanz und Sensitivität mit $\beta = 1$ .
F-2-Maß	Gewichtetes harmonisches Mittel aus Relevanz und Sensitivität mit $\beta = 2$ .

Tabelle 6: Kennzahlenmatrix der erprobten Klassifikatoren.

	Spezifität	Sensitivität	Relevanz	Segreganz	Korrekt- klassifikati- onsrate	F- Maß	F-2- Maß
MLP (CNN+FCNN) Sensor- & Bilddaten	0,77	<b>0,78</b>	0,74	<b>0,81</b>	0,78	0,76	<b>0,77</b>
MLP (FCNN) Sensordaten	0,78	0,62	0,71	0,71	0,71	0,66	0,64
MLP (FCNN) Sensordaten & Bildmerkmale	0,83	0,68	0,77	0,76	0,76	0,72	0,69
MLP (FCNN) Sensordaten & PCA	0,75	0,75	0,71	0,78	0,75	0,73	0,75
LVQ1 Sensor- & Bilddaten	<b>0,99</b>	0,01	0,6	0,55	0,55	0,02	0,01
LVQ1 Sensordaten	0,92	0,38	0,8	0,64	0,68	0,52	0,43
LVQ1 Sensordaten & Bildmerkmale	0,93	0,36	0,8	0,63	0,67	0,5	0,4
LVQ1 Sensordaten & PCA	0,92	0,37	0,79	0,64	0,67	0,5	0,41
GLVQ Sensor- & Bilddaten	0,71	0,54	0,61	0,65	0,63	0,57	0,55
GLVQ Sensordaten	0,85	0,52	0,74	0,68	0,7	0,61	0,55
GLVQ Sensordaten & Bildmerkmale	0,96	0,28	0,85	0,61	0,65	0,42	0,32
GLVQ Sensordaten & PCA	0,98	0,3	<b>0,91</b>	0,63	0,67	0,45	0,35
SVC Sensor- & Bilddaten	0,79	0,74	0,74	0,79	0,77	0,74	0,74
SVC Sensordaten	0,81	0,53	0,7	0,68	0,69	0,61	0,56
SVC Sensordaten & Bildmerkmale	0,81	0,66	0,74	0,74	0,74	0,7	0,68
SVC Sensordaten & PCA	0,89	0,72	0,85	0,79	<b>0,81</b>	<b>0,78</b>	0,74

Anhand der in Tabelle 5 und Tabelle 6 sowie der auf den Seiten 119 und 120 gezeigten Konfusionsmatrizen kann eine vergleichende Bewertung der Klassifikatoren stattfinden. Zusätzlich dazu können anhand dieser Informationen aber auch bestimmte Verhaltenseigenschaften der betrachteten Klassifikatoren abgelesen werden.

In der Gesamtbetrachtung ist dabei zunächst feststellbar, dass die prototypenbasierten Klassifikatoren LVQ1 und GLVQ vergleichsweise schlechte Klassifikationsergebnisse liefern. Wie bereits in Kapitel 5 dieser Arbeit angenommen, ist die tatsächliche Klassifikationsfähigkeit prototypenbasierter Klassifikatoren im binären Fall stark eingeschränkt, was sich besonders im Falle einer hohen Datenkomplexität bemerkbar macht. Dies zeigt sich an einer fast durchgängig steigenden Rate korrekter Klassifizierungen über eine Reduzierung der Dimension des betrachteten Merkmalsdatenvektors. Die besten F-2-Maße ergeben sich überdies für LVQ1 sowie GLVQ bei einer Reduktion des Merkmalsdatenvektors auf Sensordaten. Besonders im Falle maximaler Datenkomplexität findet über LVQ1 so gut wie keine Verbesserung über einen Lernprozess statt (vgl. Abbildung 60) und fast alle Datenpunkte werden durchgängig als i. O. klassifiziert. Es zeigt sich anhand der Ergebnisse, dass im vorliegenden Fall eine prototypenbasierte Klassifikation über ein Distanzmaß im hochdimensionalen Raum nicht geeignet ist. Zwar sind Verbesserungen der Klassifikatorenleistung über die angewendeten Maßnahmen der Dimensionsreduzierung möglich, gleichzeitig gehen hierbei jedoch auch scheinbar relevante Informationen verloren, sodass LVQ1 sowie GLVQ gegenüber den verwendeten MLP und SVC deutlich schlechtere Klassifikationsergebnisse liefern.

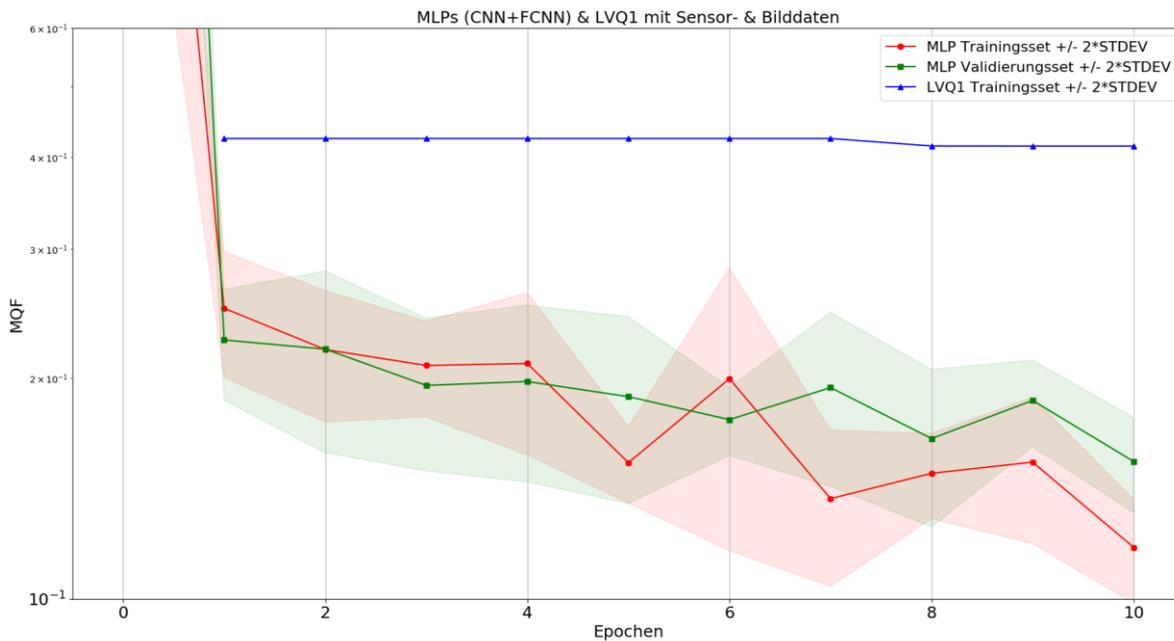


Abbildung 60: Verlauf des mittleren quadratischen Fehlers (engl. mean squared error) über die Anzahl berechneter Epochen (engl. epochs) für einen Merkmalsdatenvektor bestehend aus Sensor- und Bilddaten.

Bei einem Vergleich von SVC und MLP fällt ins Auge, dass beide Klassifikatoren zunächst ähnlich gute korrekte Klassifikationsraten liefern. Auffallend ist dabei jedoch, dass MLP-Netze dabei unter allen betrachteten Merkmalsdatenvektoren eine höhere Sensitivität aufweisen und die tatsächliche Zielsetzung einer selbstlernenden Fehlervorhersage somit besser erfüllen. Hier zeigt sich eine Schwäche von SVMs aufgrund ihrer hohen Generalisierungseigenschaften. Zwar erreicht SVC eine hohe Rate korrekt klassifizierter i. O.-Datenpunkte, welche in allen Fällen der Dimensionsreduzierung auch noch weiter steigt, jedoch stets zu Lasten einer korrekten absoluten n. i. O.-Klassifizierung. Im Falle von SVC werden somit häufig n. i. O.-Datenpunkte fälschlicherweise zu i. O.-Datenpunkten generalisiert, was sich wiederum in der hohen Spezifität aber gleichzeitig niedrigen Sensitivität äußert. Weiterhin interessant ist die bei SVC steigende korrekte Klassifikationsrate bei einer Reduzierung der gesamten Bilddaten auf die Hauptkomponenten gemäß PCA, welche ihrerseits aber zu einer Verschlechterung der Sensitivität und damit der tatsächlichen Fehlervorhersagegenauigkeit führt. Diese Beobachtung bestätigt zusätzlich die diskutierte Schwäche der hohen Generalisierungseigenschaften von SVMs.

Im Kapitel 5 dieser Arbeit konnte weiterhin bereits aufgezeigt werden, dass viele der spezifischen Vorteile von SVMs wie etwa die geringe Anforderung an die Rechenleistung im gewählten Anwendungsfall weniger relevant sind. Ein möglicher Vorteil bleibt jedoch über

die besseren Klassifikationseigenschaften von SVMs im Falle geringer Datenquantität erhalten. Abbildung 61 zeigt den Verlauf der durchschnittlichen Genauigkeit von SVM über die Anzahl der Trainingsdatenpunkte. Hierbei ist gut erkennbar, dass bereits ab einer Datenquantität von 600 Datenpunkten die Lernkurve in beiden gezeigten Fällen abflacht. Im konkreten Anwendungsfall ist die existierende Datenquantität von 1400 Trainingsdatensets somit bereits ausreichend, sodass der spezifische Vorteil von SVMs nicht mehr überwiegt und MLP-Netze besser für die Ausgestaltung einer selbstlernenden fehlervorhersagenden Systemkomponente geeignet sind.

Anhand der über die prototypische Umsetzung erzielten Ergebnisse der selbstlernenden Fehlervorhersage kann somit an dieser Stelle die in Kapitel 5 aufgestellte These bestätigt werden. Für die Ausgestaltung einer selbstlernenden Teilkomponente zur Fehlervorhersage im Rahmen der entwickelten Systemarchitektur ist die Anwendung von MLPs aus der Reihe der erprobten Klassifikatoren am besten geeignet. Die besten Ergebnisse für eine korrekte Fehlervorhersage erzielt das MLP-Netz dabei aufgrund der hohen möglichen Informationsverteilung im Netzwerk über eine Verarbeitung der maximal verfügbaren Datendimensionalität und über die Implementierung eines CNN innerhalb der Gesamtnetzstruktur.

Der Umstand, dass die Verwendung der Bilddaten als direkte Merkmale zu den besten Resultaten führt, ist seinerseits bemerkenswert. Es ist an dieser Stelle jedoch nicht ausschließbar, dass eine Verwendung entsprechend anders gewählter Bildmerkmale grundsätzlich nicht zu noch besseren Resultaten führen könnte. Unabhängig von diesem Umstand konnte jedoch aufgezeigt werden, dass eine Reduzierung der Bilddaten von direkten Merkmalen auf scheinbar relevante Bildmerkmale über die Anwendung von Expertenwissen im konkreten Anwendungsfall in schlechteren Klassifikationsergebnissen resultiert. Die Anwendung von Expertenwissen somit zu einem Verlust relevanter Informationen führt. Erklärbar ist dieser Umstand im gewählten Anwendungsfall über die hohe Neuartigkeit des betrachteten Prozesses und einer damit verbundenen hohen Unschärfe im zu diesem Zeitpunkt zur Verfügung stehenden Expertenwissen.

Für den Fall neuartiger automatisierter Montageprozesse lässt sich somit für die generelle Methodik eine möglichst allumfassende Berücksichtigung der Einflussparameter empfehlen.

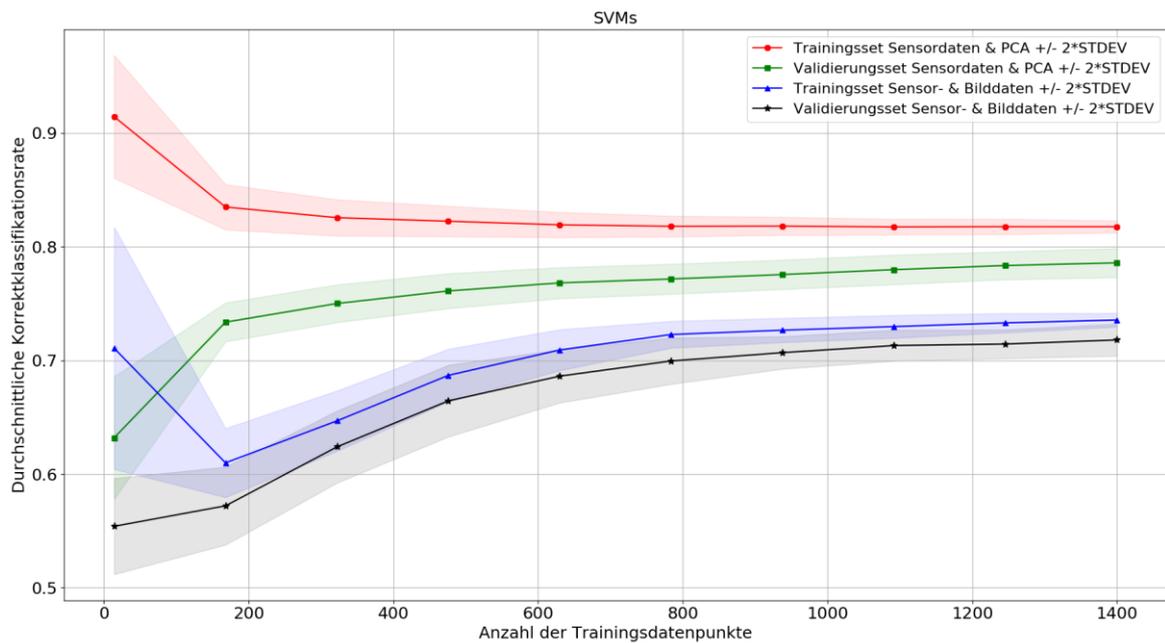


Abbildung 61: Verlauf der durchschnittlichen Genauigkeit der SVMs über die Anzahl der verwendeten Trainingsdatenpunkte für einen Merkmalsdatenvektor bestehend aus Sensordaten und PCA sowie Sensor- und Bilddaten.

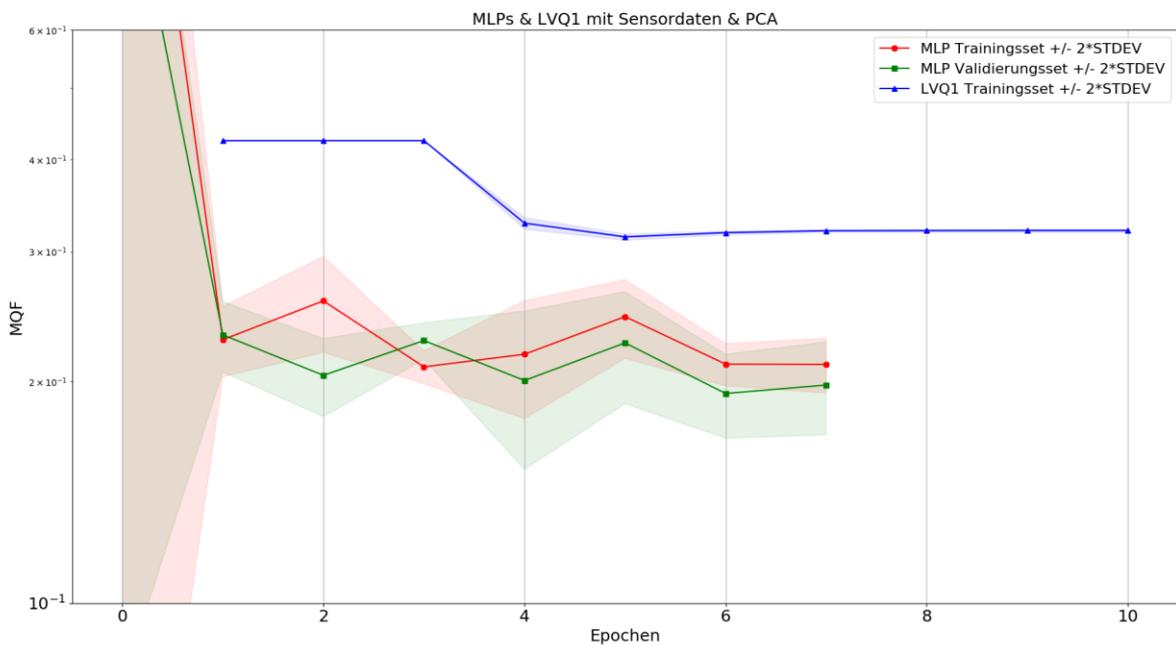


Abbildung 62: Verlauf der mittleren quadratischen Abweichung (engl. mean squared error) über die Anzahl berechneter Epochen (engl. epochs) für einen Merkmalsdatenvektor bestehend aus Sensordaten und PCA.

Anhand der vorangegangenen Diskussion bestätigt sich weiterhin erneut die Wahl des F-2-Maßes als am besten geeignetes Leistungskriterium für die Beurteilung der gewählten Klassifikatoren, da hierüber eine hohe absolute sowie relative n. i. O.-Vorhersagegenauigkeit berücksichtigt wird.

Abbildung 60 bis Abbildung 62 zeigen den Verlauf des MQF über die Anzahl der Epochen bzw. die durchschnittliche Genauigkeit über die Anzahl der Trainingsdatenpunkte für diejenigen Merkmalsdatenvektoren, welche zu den zwei besten Klassifikationsergebnissen gemäß des F-2-Maßes pro Klassifikator führen. Hierbei wurde der Mittelwert der besten fünf Berechnungsergebnisse über mehrere hundert Berechnungen aufgetragen, die Abweichung über diese fünf besten Ergebnisse wird graphisch über die Fläche in entsprechender Farbe visualisiert. Als Stoppkriterium wurde das als „early stopping“ etablierte Vorgehen gewählt, die Berechnung also mit dem Eintreten von Overfitting abgebrochen, welches über eine starke Verbesserung der Trainingskurve bei gleichzeitiger starker Verschlechterung der Validierungskurve gekennzeichnet ist.

## 6.6 Prototypische Konzeptumsetzung der Fehlervermeidung

Die prototypische Umsetzung der Fehlervermeidung erfolgte auf Basis der in Kapitel 6.3 beschriebenen Versuchsanlage und aufbauend auf den Erkenntnissen der prototypischen Umsetzung der Fehlervorhersage (vgl. Kapitel 6.5). Abbildung 63 zeigt die auf der Versuchsanlage aufbauende Systemgestaltung der prototypisch umgesetzten Fehlervermeidung. Da gemäß der in Kapitel 5 beschriebenen Handlungsstrategie eine fehlervermeidende Maßnahme nur im Falle einer Fehlervorhersage angewendet werden soll, beruht somit eine funktionierende Fehlervermeidung auch immer auf einer möglichst akkuraten Fehlervorhersage. Daher wurde die in Kapitel 6.5.2 identifizierte beste algorithmische Lösung als fehlervorhersagende Komponente in das Gesamtsystem zur prototypischen Umsetzung der fehlervermeidenden Systemkomponente integriert.

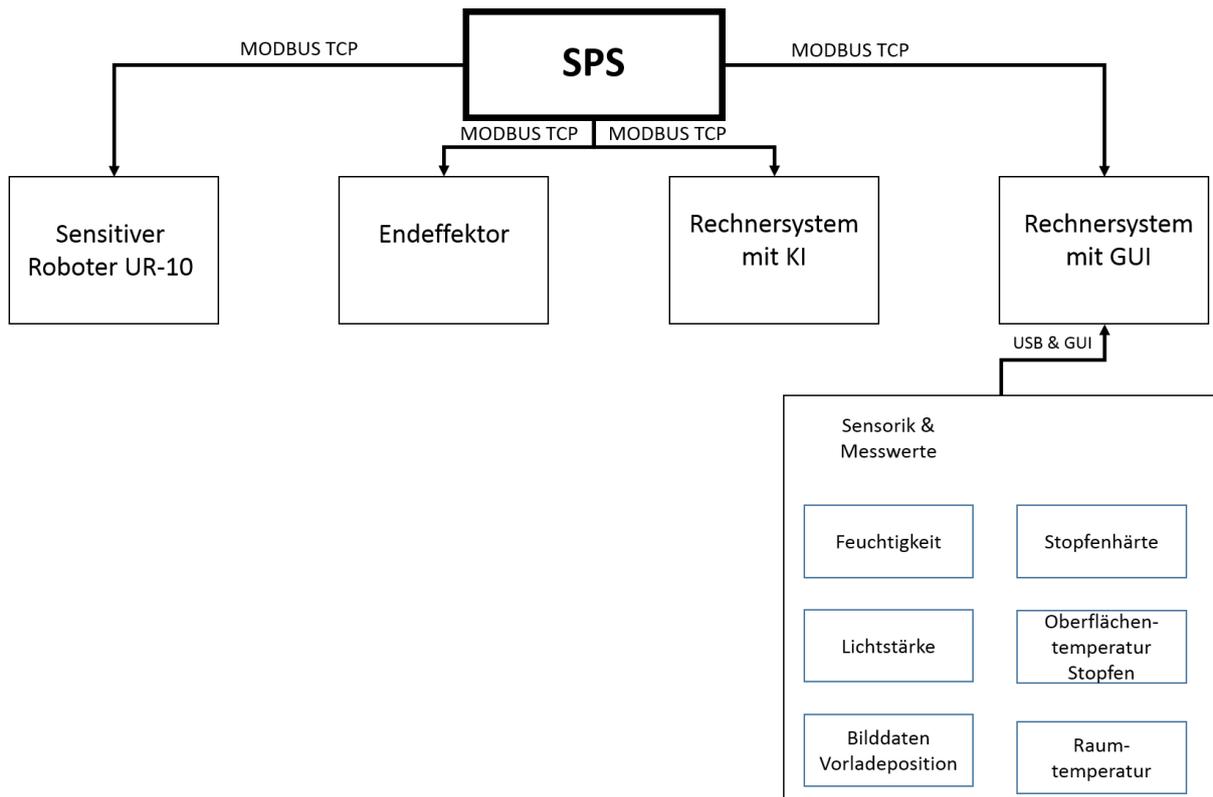


Abbildung 63: Hierarchischer Aufbau der Systemkomponenten zur Fehlervermeidung.

Zur steuerungseitigen Umsetzung der prototypischen Fehlervermeidung wurde zunächst eine hierarchische Struktur zwischen der SPS und den weiteren Systemkomponenten aufgebaut. Die Kommunikation erfolgte dabei über MODBUS TCP. Die SPS fungierte in diesem Systemaufbau als MODBUS-CLIENT und damit als Master des Gesamtsystems. Für alle in Abbildung 63 gezeigten Systemkomponenten, welche mit der SPS über MODBUS kommunizieren, wurde ein MODBUS-SERVER konfiguriert und damit eine eindeutige Master-Slave-Beziehung zwischen SPS und allen übrigen Systemkomponenten hergestellt. Die Kommunikation erfolgte dabei auf einer INPUT REGISTER- und HOLDING REGISTER-Struktur. Die Schrittkette eines Montagevorgangs wird über die SPS als MODBUS-CLIENT verwaltet und die Kommunikation über eine Client-Aufruf- und Server-Antwort-Beziehung gesteuert. Abbildung 64 zeigt diesen Austausch an einem Beispiel in Pseudocode.

```

CLIENT:
...
    case 1:
        MB_CONFIG_forServer
        MB_READ_from_SYSTEMKOMPONENTE_X
        MB_WRITE_to_SYSTEMKOMPONENTE_X
        set HoldingRegister X=0 //Systemkomponente X bereit
        MB_WRITE_to_X(task=1)
        wait until (MB_READ_from_X.HoldingRegister=(task))
        MB_WRITE_to_X(task=0) // Bestätigung und Verhinderung einer Endlosschleife
    case 2:
        ....
        MB_WRITE_to_X(task=2)
    ....
SERVER:
...
    while 1:
        task = READ_FROM_InputRegister
        switch task:
            case 1:
                set HoldingRegister = task
                wait until InputRegister = 0
            case2:...

```

---

Abbildung 64: Darstellung der MODBUS-CLIENT- zu SERVER-Kommunikation.

Der Prozess der Fehlervermeidung pro Stopfen untergliedert sich dabei wie folgt:

1. SPS setzt den Task X.
2. SPS empfängt die Eingangsvariablen und sendet diese an die KI-Workstation.
3. SPS setzt Task Y.
4. Fehlervorhersage wird auf der KI-Workstation ausgeführt (NN.predict(data)).
5. Falls kein Fehler vorhergesagt wird, führe den Verbau aus und speichere Ergebnis.
6. Falls ein Fehler vorhergesagt wird, bestimme Erwartungswert der Belohnung für alle Gegenmaßnahmen und wähle daraus Gegenmaßnahme Z mit dem höchsten Erwartungswert.
7. Führe Verbau zusammen mit Gegenmaßnahme Z aus und speichere Ergebnis.

Die Bestimmung des Erwartungswertes der Belohnung für jede mögliche Gegenmaßnahme im aktuellen Systemzustand findet hierbei über den in Kapitel 5.2.2 definierten Ansatz Deep Q-Learning statt. Die exakte Umsetzung dieses Ansatzes wird im Folgenden näher erläutert. Wie bereits in Kapitel 5.2.2 aufgezeigt wurde, besteht der Grundansatz von Deep Q-Learning in der Kombination des Reinforcement Learning-Ansatzes Q-Learning mit einer neuronalen Netzstruktur, welche als Funktionsapproximation der Wertefunktion zur

Bestimmung des erwarteten Belohnungswertes fungiert. Das neuronale Netz besteht hierbei, exakt wie die in Kapitel 6.5.2 identifizierte beste Klassifikatorstruktur, aus einer Kombination eines CNN mit einem FCNN. Die Netzstruktur verfügt für jede mögliche Maßnahme über einen Ausgangsknoten, an welchem der approximierte Erwartungswert der Belohnung ausgegeben wird.

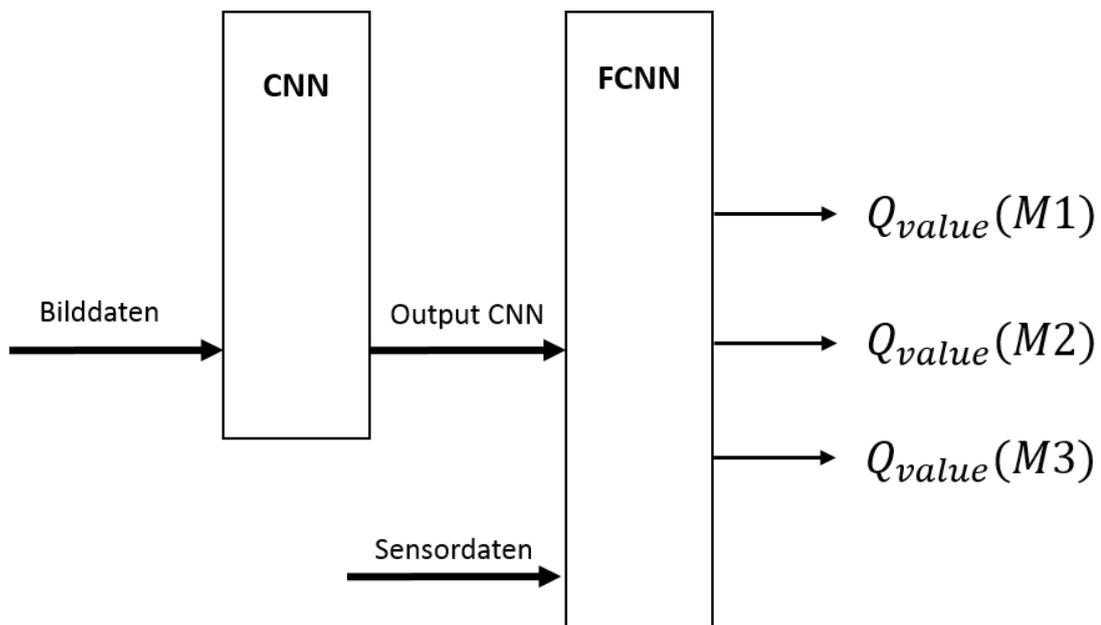


Abbildung 65: Netzarchitektur des QNN

Für die konkrete prototypische Realisierung der Fehlervermeidung wurden folgende drei mögliche Gegenmaßnahmen bestimmt:

- M1: Erhöhung der Andrückkraft um 10% im Montageprozess.
- M2: Nachpositionierung der Vorladeposition des Stopfens um 1mm nach vorne und anschließender Montageprozess.
- M3: Abwerfen des aktuellen Stopfens und Setzen des nachfolgenden Stopfens ohne erneute Fehlervorhersage.

Anhand der gewählten Maßnahme ist gut ersichtlich, dass nicht alle Gegenmaßnahmen gleich vorteilhaft sind, eine jede Gegenmaßnahme aber besser eingestuft wird als ein auftretender Fehler im Montageergebnis. Gegenmaßnahme M1 führt aufgrund der hohen Prozesskräfte zu einem erhöhten Verschleiß und Gegenmaßnahme M3 führt zum Verlust eines Stopfens für die weitere Montage. Lediglich Gegenmaßnahme M2 ist aus Gesamtprozesssicht mit keinem Nachteil verbunden.

Aus Gesamtprozesssicht existiert daher folgende Rangfolge, wobei Position 1 das am stärksten präferierte Szenario und Position 8 das am wenigsten präferierte Szenario darstellt.

1. Montageergebnis ohne Gegenmaßnahme i. O.
2. Montageergebnis unter Gegenmaßnahme M2 i. O.
3. Montageergebnis unter Gegenmaßnahme M1 i. O.
4. Montageergebnis unter Gegenmaßnahme M3 i. O.
5. Montageergebnis n. i. O.
6. Montageergebnis unter Gegenmaßnahme M2 n. i. O.
7. Montageergebnis unter Gegenmaßnahme M1 n. i. O.
8. Montageergebnis unter Gegenmaßnahme M3 n. i. O.

Zur korrekten und zielführenden Inzentivierung der selbstlernenden fehlvermeidenden Systemeigenschaften erfolgt die Ausgestaltung der Belohnungsfunktion des Algorithmus entsprechend des in Kapitel 5.2.2 (Seite 77) beschriebenen Ansatzes.

Der eingesetzte Deep Q-Learning-Algorithmus verwendet einen Erfahrungspuffer und verfolgt eine „ $\epsilon$ -Greedy“-Strategie. Zur Stabilisierung der neuronalen Netzstruktur findet weiterhin „Experience Replay“ statt. Abbildung 66 gibt einen Überblick über den verwendeten Algorithmus in Pseudocode in Ablehnung an Mnih et al. (2013). Der hierfür adaptierte Algorithmus unterscheidet sich dabei grundlegend in der Tatsache, dass für den hier beschriebenen Anwendungsfall eine Maßnahme immer zu einem Endzustand mit einer einmaligen Belohnung führt, also keine Summe zukünftiger erwarteter Belohnungen betrachtet wird.

---

**Verwendeter Algorithmus Deep Q-Learning mit Experience Replay zur Q-Value Approximation**


---

```

Initialize ExperienceBuffer D to capacity N
Initialize  $Q_{value}$  Function with random weights
set  $\epsilon_{start} = 1$ 
set  $\epsilon_{stop} = 0,01$ 
    
```

KI Workstation receives (data) which defines system state  $s$

```

set  $y = \text{random}(0;1)$ 
  if  $y < \epsilon$ 
    select random action  $a$ 
  else
     $Q_{value} = \text{self.tf.run}(rlAgent.predict, s)$ 
    select action  $a = \max_a(Q_{value})$ 
  execute action  $a$  and observe reward  $r$ 
  store  $(a, s, r)$  in ExperienceBuffer  $D$ 
  if  $\epsilon > \epsilon_{stop}$ 
     $\epsilon = \epsilon - 0,0165$ 
  sample random minibatch  $d$  from  $D$ 
  reward =  $RLAgent.get\_reward(d)$ 
   $RLAgent.rlAgent.update(\text{minibatch}, \text{reward})$  // Ausführung Experience Replay auf Minibatch  $d$ 
    
```

---

Abbildung 66: Verwendeter Algorithmus Deep Q Learning mit iterativ fallender  $\epsilon$ -Greedy-Strategie und Experience Replay.

Der in Abbildung 66 gezeigte und für die Fehlervermeidung implementierte Algorithmus wählt somit im Falle einer Fehlervorhersage zunächst mit einer Wahrscheinlichkeit  $\epsilon$  eine zufällige Gegenmaßnahme. Mit der Wahrscheinlichkeit  $1 - \epsilon$  wird bei einer Fehlerprognose die erwartete Belohnung ( $Q_{value}$ ) für den gegebenen Systemzustand  $s$  einer jeden zur Verfügung stehenden Gegenmaßnahme über die in Abbildung 65 gezeigte QNN-Struktur bestimmt und anschließend die Gegenmaßnahme mit der höchsten zu erwartenden Belohnung ausgewählt. In beiden Fällen erfolgt eine iterative Reduzierung von  $\epsilon$  bis  $\epsilon = 0,01$  gilt. Anschließend erfolgt das in Mnih et al. (2013) beschriebene Verfahren „Experience Replay“ zur Stabilisierung der algorithmischen Eigenschaften.

## 6.7 Ergebnisse der umgesetzten Fehlervermeidung

Das beschriebene selbstlernende fehlervermeidende Montagesystem wurde anschließend im Rahmen einer Testreihe erprobt. Hierbei erfolgt der beschriebene Montagevorgang von Verschlussstopfen jeweils 250 Mal in 3 Szenarien und unter möglichst vergleichbaren Bedingungen. In Szenario 1 erfolgt der Verbau unter Einstellung eines festen Montageparametersets, welches aus der Parameterwahl eines realen Anlaufprozesses abgeleitet wurde. Es findet zwar eine Fehlervorhersage aber keine selektive Auswahl und Einleitung einer Gegenmaßnahme statt. In Szenario 2 erfolgt auf Basis der selbstlernenden fehlervorhersagenden Systemkomponente für den Fall einer Fehlervorhersage die zufällig gleichverteilte Auswahl und Einleitung einer der Gegenmaßnahmen M1, M2 oder M3 Anwendung. Szenario 3 stellt die Umsetzung der selbstlernenden Fehlervermeidung in das vorliegende Montagesystem dar. Dabei erfolgt die Auswahl und Einleitung der Gegenmaßnahmen basierend auf dem zuvor beschriebenen Deep Q-Learning Ansatz.

Abbildung 67 umfasst die Ergebnisse in den drei beschriebenen Szenarien. Hierbei zeigt sich, dass die erreichte Güte der fehlervorhersagenden Systemkomponente in allen drei Szenarien fast identisch gute Ergebnisse liefert und damit eine sinnvolle Vergleichbarkeit der Resultate der anschließenden und darauf basierenden Fehlervermeidung möglich ist. Im ersten Szenario ohne Fehlervermeidung konnten lediglich 113 der ausgeführten 250 Montagevorgänge korrekt und damit i. O. ausgeführt werden. Gleichzeitig konnten aber fast 70 % der stattfindenden Fehler im Montageprozess korrekt vorhergesagt werden. Über die Auswahl und Anwendung einer zufällig gleichverteilten Gegenmaßnahme in Szenario 2 konnte die Rate korrekter Montagevorgänge bereits auf 149 und damit die Fehlerrate um 26 % auf nur noch 101 fehlerhafter Montageergebnisse reduziert werden. Durch die Anwendung des entwickelten neuartigen Ansatzes selbstlernender fehlervermeidender Systemeigenschaften in Szenario 3 konnte anschließend sogar eine drastische Reduzierung der auftretenden Fehlerrate von 35 % realisiert werden.



Abbildung 67: Ergebnisse der umgesetzten Fehlervermeidung in drei Szenarien.

Es lässt sich weiterhin festhalten, dass bereits auf der Grundlage von 250 ausgeführten Montagevorgängen ein äußerst effizienter Lernprozess in der fehlervermeidenden Systemkomponente stattgefunden hat. Dabei erfolgt die optimierte Anwendung der Gegenmaßnahme M2 mit der offensichtlich höchsten Wahrscheinlichkeit (vgl. Abbildung 67) einer Fehlervermeidung in 78,4 % der Fälle einer ausgeführten Fehlervermeidung. Über die Implementierung der selbstlernenden fehlervermeidenden Systemkomponente in Szenario 3 findet überdies eine Verbesserung der Erfolgsquoten in allen angewandten Gegenmaßnahmen statt. Dieser Umstand ist besonders bemerkenswert da hiermit gezeigt werden konnte, dass der entwickelte Ansatz somit für jeden individuellen Systemzustand erlernt, welche der zur Verfügung stehenden Gegenmaßnahmen einen etwaig auftretender Fehler am erfolgreichsten vermeiden kann und damit die generelle Eignung des entwickelten Konzeptes vor dem Hintergrund der Zielsetzung dieser Arbeit bestätigt werden kann.

## 6.8 Fazit und Konzeptbestätigung

Die dargelegten technischen Umsetzungen haben gezeigt, dass das entwickelte System in der Lage ist Fehler im Montageergebnis einer Beispieltechnologie, welche durch eine Veränderung der externen Einflussvariablen auf einen neuartigen Prozess in einem AnlaufszENARIO resultieren, zielgerichtet vorherzusagen und über die Einleitung entsprechender Gegenmaßnahmen zu verhindern. Für die Fehlervorhersage konnte im ausgewählten Szenario eine allgemeine Vorhersagegüte von 78 % erreicht werden. Eine beispielhaft auftretende

Fehlerrate von 10 % kann damit auf ca. 2 % selbstlernend reduziert werden, was wiederum einer Steigerung von 90 % auf 98 % in der Qualitätsleistung der Montageanlage entspricht. Über die Implementierung der selbstlernenden fehlervermeidenden Systemkomponente konnte eine drastische Reduzierung der auftretenden Fehlerrate von 35 % realisiert werden. Das entwickelte System kann somit maßgeblich zur Ausgestaltung einer notwendigen eigenständigen Störungsrobustheit neuartiger automatisierter Montagesysteme in der Automobilproduktion und im Speziellen in der Automobilendmontage eingesetzt werden. Bezüglich der selbstlernenden fehlervermeidenden Systemkomponente konnte im Rahmen dieser Arbeit weiterhin gezeigt werden, dass über die Implementierung eines Deep Q-Learning-Algorithmus eine stabile selbstlernende Zuordnung bekannter wie unbekannter Systemzustände zu den jeweils präferierten fehlervermeidenden Gegenmaßnahmen möglich ist. Abbildung 68 zeigt den in Kapitel 5 beschriebenen entwickelten Systementwurf und ergänzt diesen um die in diesem Kapitel bestätigten identifizierten algorithmischen Umsetzungen.

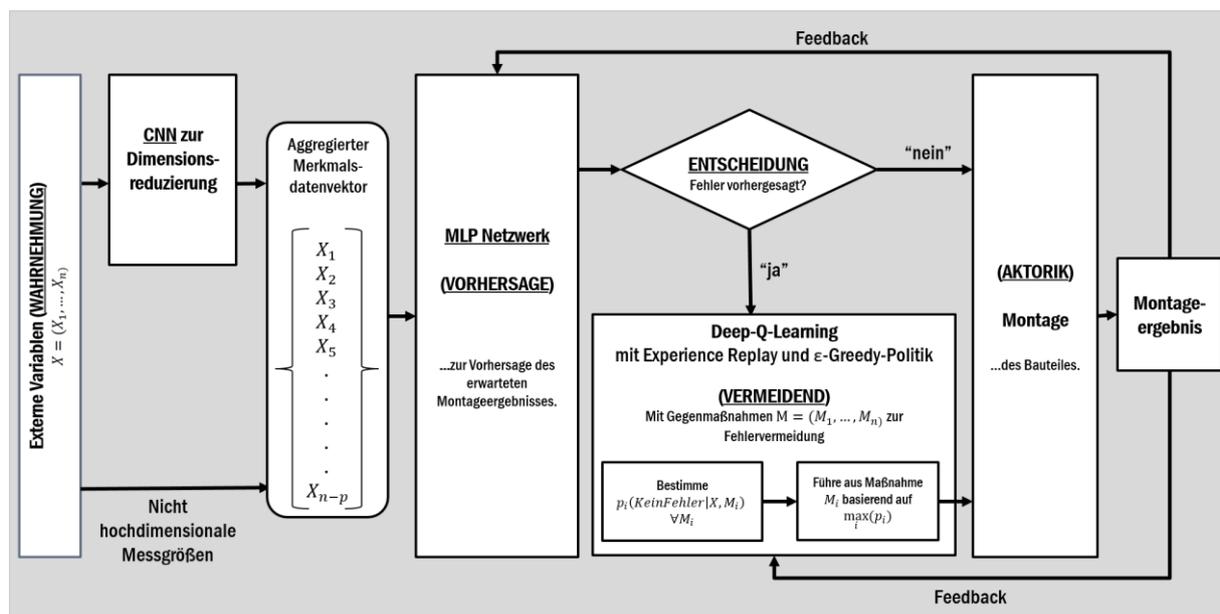


Abbildung 68: Bestätigte Gesamtsystemarchitektur mit identifizierter algorithmischer Umsetzung.

## 6.9 Zusammenfassung

Im vorliegenden Kapitel 6 erfolgte die Beschreibung der prototypischen Umsetzung des in Kapitel 5 beschriebenen Systementwurfs zur selbstlernenden Fehlervermeidung automatisierter Montagesysteme im Produktionsanlauf. Die prototypische Umsetzung und Untersuchung der hergeleiteten wissensbasierten Systemarchitektur erfolgte dabei anhand eines zu

Beginn des Kapitels eingeführten und mehrstufigen Prozessmodelles. Im Rahmen des Prozessstufenmodelles wurde die automatisierte Stopfenmontage aus der Menge übertagbarer Montageprozesse ausgewählt und näher erläutert. Im anschließenden Kapitel 6.3 erfolgte für eine Nachvollziehbarkeit der gemachten prototypischen Ergebnisse eine detaillierte Beschreibung der konzeptionierten Versuchsanlage sowie der damit durchgeführten Erzeugung von Versuchsdaten. Aufbauend auf der beschriebenen Versuchsanlage wurden anschließend in Kapitel 6.4 zunächst die identifizierten algorithmischen Möglichkeiten zur Ausgestaltung einer selbstlernenden Fehlervorhersage implementiert sowie in Kapitel 6.5 einem Leistungsvergleich unterzogen. Dabei konnte die in Kapitel 5.2 aufgestellte These bestätigt werden und die Anwendung eines MLP-Netzwerkes als beste der betrachteten Lösungen aufgezeigt werden. In Kapitel 6.6 und Kapitel 6.7 wurden anschließend die Implementierung sowie die Ergebnisse des Gesamtsystems zur selbstlernenden Fehlervermeidung beschrieben. Es konnte dabei gezeigt werden, dass der entwickelte Systementwurf zielgerichtet Montagefehler in einem AnlaufszENARIO der Beispieltechnologie vorhersagen und vermeiden kann, und das entwickelte Konzept die Gesamtzielsetzung dieser Arbeit zur Ausgestaltung einer selbstlernenden Störungsrobustheit im Produktionsanlauf erfüllt.

## 7 Validierung

Der in vorgelagerten Kapiteln entwickelte Systementwurf zur Konzeptionierung eines selbstlernenden automatisierten Montagesystems zur Fehlervermeidung im Produktionsanlauf wurde im Kapitel 6 dieser Arbeit prototypisch umgesetzt. Die prototypische Umsetzung erfolgte dabei über den in Kapitel 6.3 beschriebenen Versuchsaufbau, anhand dessen die Aufnahme von Versuchsdaten für die Erprobung, Auswahl und Validierung des entwickelten Konzepts erfolgte.

Aufbauend auf dieser bereits in Kapitel 6 erfolgten nachgewiesenen Wirkungsweise des entwickelten Konzepts muss in diesem Kapitel noch eine Validierung der über den Versuchsaufbau erzeugten Datensätze sowie der algorithmisch erreichten Wirksamkeit erfolgen.

### 7.1 Validierung der verwendeten Versuchsdatensätze

Kapitel 6.3.2 dieser Arbeit beschreibt die Datenaufnahme von Versuchsdatensätzen im Rahmen der prototypischen Umsetzung des entwickelten Konzepts. Die erhobenen Datensätze sind vor dem Hintergrund der Zielsetzung dieser Arbeit dann als valide anzusehen, falls diese in derselben oder ähnlichen Form auch in der realen Serienproduktion des beschriebenen Vergleichsprozesses beobachtbar sind. In diesem Kapitel erfolgt daher für jede der in den Versuchsdaten aufgenommenen externen Variablen eine Diskussion hinsichtlich der Ähnlichkeit der erfassten Versuchsdaten zu den im Serienbetrieb auftretenden Realgrößen.

### **Erfasste Stopfenhärte**

Zur Erhebung der Versuchsdaten im Rahmen der prototypischen Umsetzung wurden originale Verschlussstopfen zu unterschiedlichen Zeitpunkten und aus unterschiedlichen Werkstandorten erfasst und für die Erhebung der Versuchsdaten verwendet. Es handelt sich dabei somit um die exakt identischen Verschlussstopfen wie für den Serienprozess. Die erfassten Stopfenhärten entsprechen daher den im Serienprozess messbaren Größen.

### **Erfasste Oberflächentemperatur**

Zur Gewährleistung einer repräsentativen Oberflächentemperatur erfolgte zunächst die Auswertung der Jahrestemperaturen eines Lagerstandortes für Verschlussstopfen über ein Kalenderjahr hinweg. Anhand des daraus ausgewerteten realen Werteintervalls und der relativen Verteilung erfolgte anschließend die Erzeugung der Versuchsdaten über das real aufgetretene Temperaturintervall mit vergleichbarer Häufigkeit der auftretenden Temperaturen. Hierbei wurde bewusst zwischen vorherrschender Raumtemperatur und Oberflächentemperatur der Verschlussstopfen unterschieden, da besonders in den Winter- und Sommermonaten eine Lagerung der Stopfen ober- bzw. unterhalb der Raumtemperatur der Produktionsumgebung möglich ist.

### **Erfasste Vorladeposition des Stopfens**

Über die Verwendung von Verschlussstopfen aus dem Serienprozess und über eine exakte Kopie des im Serienprozess verwendeten Endeffektors sind die diesbezüglich erzeugten Versuchsdaten als ebenfalls valide anzusehen.

### **Lochtyp**

Für die Erhebung der Versuchsdaten wurde ein Teilabschnitt einer Originalkarosse verwendet, wie diese auch in der Serienanlage verwendet wird. Die auftretenden Lochtypen und Geometrien entsprechen daher dem Serienprozess. Hierbei findet der Verbau der Verschlussstopfen zwar nicht im Fahrzeugfluss statt, der durch diesen Fluss resultierende Einfluss mechanischer Toleranzen im Serienprozess kann aufgrund der existierenden Klemmung der Karosse und einer integrierten 2-D-Kameratechnik zur Lochfindung jedoch als geringfügig ( $x \leq 0,5\text{mm}$ ) eingestuft werden.

### **Erfasste Luftfeuchtigkeit, Lichtstärke und Raumtemperatur**

Zur Gewährleistung der Vergleichbarkeit der auftretenden äußeren Umstände im Realprozess und während der Erhebung der Versuchsdaten erfolgte der Aufbau der Versuchsanlage innerhalb eines Produktionsgebäudes des Automobilherstellers. Aufgrund der dabei vorherrschenden Standardisierung der Produktionsstrukturen können die im Produktionsgebäude des Versuchsaufbaus auftretenden Luftfechtigkeiten und Lichtstärken als gleichartig zum Serienprozess angenommen werden.

## **7.2 Validierung der Ergebnisse**

### **7.2.1 Ergebnisse der Fehlervorhersage**

Im Kapitel 6.5.2 dieser Arbeit wurde ein Leistungsvergleich unterschiedlicher identifizierter maschineller Lernalgorithmen hinsichtlich deren Eignung als Klassifikator zur Gestaltung einer selbstlernenden Teilkomponenten (vgl. Kapitel 5) zur Fehlervorhersage an einer automatisierten Montageanlage durchgeführt. Hierbei konnte die in Kapitel 5.2 formulierte These bestätigt und eine Kombination aus CNN und FCNN im Rahmen eines MLP-Netzes als beste der betrachteten algorithmischen Lösungen bestätigt werden. Dabei erfolgte für jeden ausgewählten Klassifikator eine Validierung der Leistungsfähigkeit anhand eines für den Klassifikator bis dahin unbekanntes Validierungsdatensatzes.

Zur weiteren Bestätigung der über das MLP-Netz erreichbaren generell guten Klassifikationsergebnisse erfolgte zusätzlich eine 3-fache Kreuzvalidierung der erhobenen Ergebnisse. Hierfür wurde eine Unterteilung der gesamten Datenmenge bestehend aus 2000 Datenpunkten in drei jeweils beinahe gleich große Unterdatenmengen, bestehend aus zweimal 667 Datenpunkten und einmal 666 Datenpunkten, durchgeführt. Anschließend fand das Training des Netzes anhand der übrigen 1333 bzw. 1334 Datenpunkte statt. Da über einen Merkmalsdatenvektor bestehend aus Sensor und Bilddaten die besten Klassifizierungsergebnisse im Rahmen der prototypischen Erprobung erreicht wurden (vgl. Kapitel 6.4) erfolgte die Kreuzvalidierung auf diesem Merkmalsdatenvektor.

Abbildung 69 zeigt die Konfusionsmatrizen der drei unabhängigen Klassifizierungen über das MLP-Netz. Tabelle 7 zeigt die daraus abgeleiteten und in Kapitel 6.5 dieser Arbeit eingeführten Kennzahlen zum Leistungsvergleich der Klassifikatoren.

MLP (CNN+FCNN) mit Sensor- und Bilddaten auf Datensatz 1

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	234	79	313
Vorhersage I.O.	65	288	353
Summe	299	367	666

MLP (CNN+FCNN) mit Sensor- und Bilddaten auf Datensatz 2

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	225	103	328
Vorhersage I.O.	64	275	339
Summe	289	378	667

MLP (CNN+FCNN) mit Sensor- und Bilddaten auf Datensatz 3

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	217	97	314
Vorhersage I.O.	62	291	353
Summe	279	388	667

Abbildung 69: Konfusionsmatrizen der 3-fachen Kreuzvalidierung.

Tabelle 7: Kennzahlenmatrix der 3-fachen Kreuzvalidierung.

	Spezifität	Sensitivität	Relevanz	Segreganz	Korrektklassifikationsrate	F-Maß	F-2-Maß
MLP (CNN+FCNN) Sensor- & Bilddaten Datensatz 1	0,78	0,78	0,75	0,82	0,78	0,76	0,78
MLP (CNN+FCNN) Sensor- & Bilddaten Datensatz 2	0,73	0,78	0,69	0,81	0,75	0,73	0,76
MLP (CNN+FCNN) Sensor- & Bilddaten Datensatz 3	0,75	0,78	0,69	0,82	0,76	0,73	0,76
Mittelwert	0,75	0,78	0,71	0,82	0,76	0,74	0,77

Über die 3-fache Kreuzvalidierung zeigt sich eine nur minimale Veränderung der berechneten Kennzahlen und eine Abweichung des F-2-Maßes von kleiner gleich  $\pm 0,01$  gegenüber den in Kapitel 6.5.2 gezeigten Ergebnissen.

Die Bestätigung einer statistischen Abhängigkeit zwischen Klasse und Klassifizierungsergebnis kann über die berechneten Kennzahlen Sensitivität und Segreganz abgeleitet werden. Ein Wert von 1 würde hier einer perfekten Korrelation zwischen Klasse und Klassifizierungsergebnis entsprechen. Aufgrund des beobachtbaren Wertebereiches von 0,82 bis 0,78 zeigt sich auch hier eine starke Korrelation, welche die Wirksamkeit des Klassifikators zusätzlich bestätigt.

Hieraus kann eine Generalisierung der beobachteten guten Ergebnisse des MLP-Netzes abgeleitet werden und somit die generelle Eignung des beschriebenen Klassifikators zur allgemeinen Anwendung einer fehlervorhersagenden Teilkomponente im entwickelten Konzept einer selbstlernenden Fehlervermeidung automatisierter Montagesysteme im Produktionsanlauf der Fahrzeugproduktion bestätigt werden.

### 7.2.2 Ergebnisse der Fehlervermeidung

Aufgrund der existierenden hohen Datenkomplexität ist eine einfache Reproduzierbarkeit einzelner Fehlerfälle mit entsprechender Gegenmaßnahme nicht umsetzbar und damit die Möglichkeiten einer sinnvollen Kreuzvalidierung für die selbstlernende Fehlervermeidung erschwert. In Kapitel 6.7. konnte jedoch bereits die besondere Eignung des beschriebenen Deep Q-Learning Ansatzes für die Ausgestaltung einer selbstlernenden fehlervermeidenden Systemkomponente im Rahmen dieser Arbeit bestätigt werden. Die Überlegenheit des entwickelten Ansatzes gegenüber einer Methode ohne Gegenmaßnahme sowie gegenüber einer Methode mit zufälliger Gegenmaßnahme konnte dabei gezeigt werden, was wiederum eine weitergehende Validierung der erhaltenen Versuchsergebnisse im Rahmen dieser Arbeit nicht weiter notwendig macht.

## 8 Zusammenfassung und Ausblick

Im Rahmen der vorliegenden Arbeit wurde die Entwicklung eines Konzeptes zur selbstlernenden Fehlvermeidung automatisierter Montagesysteme im Anlauf der Fahrzeugproduktion beschrieben und hinsichtlich seiner Wirksamkeit und Anwendbarkeit validiert. Die Realisierung einer verbesserten Anlaufzielerreichung über die Implementierung einer selbstständigen und lernenden Fehlvermeidung auf Ebene automatisierter Montagesysteme stellt dabei eine bisher nicht berücksichtigte Neuheit im aktuellen Stand der Forschung und Technik dar. Aufgrund der aufwandsarmen Natur selbstlernender Systemeigenschaften zur Fehlvermeidung eignet sich das entwickelte Konzept dabei und im Gegensatz zu zahlreichen existierenden Ansätzen für eine breite Anwendung in der betrieblichen Praxis produzierender Unternehmen in der heutigen Zeit.

Die vorliegende Arbeit beginnt mit der Vorbetrachtung existierender Automatisierungspotentiale in den Teilsystemen der Fahrzeugproduktion. Hierbei existiert insbesondere im Bereich der Automobilendmontage heutzutage mit etwa 5-10 % Automatisierungsgrad noch ein großes bisher ungenutztes Potential für die Anwendung von Automatisierungssystemen. Gleichzeitig stattfindende gesellschaftliche Entwicklungen wie die zunehmende Alterung westlicher Gesellschaften im Rahmen des demographischen Wandels, steigende Lohnkosten aber auch technologische Neuentwicklungen wie sensitive Roboter und eine zunehmende Vernetzung über cyber-physische Systeme machen eine Zunahme automatisierter Montagesysteme gesellschaftlich notwendig und technologisch möglich. Speziell im Umfeld der Automobilendmontage herrscht aufgrund der häufig starren Verkettung eine besonders hohe Anforderung an die Störungsrobustheit solcher Systeme. Dies zeigt sich bereits heute in den existierenden Herausforderungen im Umfeld der betrieblichen Praxis, was wiederum die Forderung nach einer zunehmenden aktiven Beherrschung zukünftiger Produktionsanläufe im Rahmen eines zeitgemäßen Anlaufmanagements bestärkt. Die

heute gängigen modellbasierten Verfahren zur Ausgestaltung intelligenter Regelungssysteme erscheinen für eine potentiell stark ansteigende Anzahl neuartiger automatisierter Montageprozesse und vor dem Hintergrund einer im Produktionsanlauf existierenden hohen prozessualen Unsicherheit häufig nicht geeignet für die Ausgestaltung einer zunehmenden Störungsrobustheit. Viele Situationen ereignen sich im Produktionsanlauf das erste Mal und insbesondere datengetriebene Ansätze mit ihrer Fähigkeit zur eigenständigen Erkennung und Verarbeitung komplexer Muster erscheinen geeignet.

Vor dem Hintergrund dieser Vorbetrachtungen und Rahmenbedingungen werden anschließend Anforderungen an eine zeitgemäße Anlaufsteuerung von Automatisierungsanlagen in der Automobilendmontage abgeleitet und über die Formulierung von Leitsätzen konkretisiert und ergänzt.

Über eine Analyse der existierenden Ansätze für das Anlaufmanagement in der Automobilindustrie sowie einer anschließenden Ergänzung dieser Perspektive über die Betrachtung von Ansätzen zum Umgang mit Störungen im Produktionsanlauf wurde aufgezeigt, dass gegenwärtig keiner dieser Ansätze die abgeleiteten Anforderungen erfüllt und somit zum aktuellen Zeitpunkt kein Konzept existiert wie Fehler, die im Anlauf durch eine natürliche Variation der Umwelteinflüsse hervorgerufen werden, eigenständig von einem Montagesystem vermieden werden können.

Aufbauend auf dem hieraus resultierenden Forschungsbedarf wurde im Rahmen der vorliegenden Arbeit ein Konzept zur eigenständigen Anpassung roboterbasierter Montageprozessanlagen zur Vermeidung von anlaufbezogenen Montagefehlern entwickelt und in einem Systementwurf beschrieben. Die Realisierung einer eigenständigen und selbstlernenden Fehlvermeidung stellt dabei eine absolute Neuheit im existierenden Stand der Forschung und Technik dar. Das entwickelte System erfüllt dabei alle abgeleiteten Anforderungen an eine zeitgemäße Anlaufsteuerung und lässt sich in eine selbstlernende Teilkomponente zur Fehlervorhersage und eine selbstlernende Teilkomponente zur Fehlervermeidung unterteilen. Über eine derartige Konzeptionierung des Gesamtsystems kann eine Abweichung von einer gegebenen Montagestrategie nur im Falle einer positiven Fehlervorhersage erfolgen, und damit die Realisierung einer menschlichen Handlungsstrategie zur Vermeidung von Montagefehlern im Produktionsanlauf.

Da besonders im Umfeld der Automobilendmontage ein zunehmender Bedarf an einer aktiven Beherrschung automatisierter Montageanlagen im Produktionsanlauf existiert, erfolgte die prototypische Umsetzung des entwickelten Ansatzes an einem ausgewählten Beispielsprozess aus diesem Umfeld. Der prototypische Aufbau umfasste dabei den vollumfänglichen Systementwurf und damit die gesamthafte Berücksichtigung der abgeleiteten Anforderungen. Über einen Expertenworkshop wurden zunächst die relevanten externen Einflussvariablen identifiziert. Über einen Leistungsvergleich verschiedener existierender Algorithmen und Ansätze konnte die prinzipielle Eignung einer Datenvorverarbeitung über ein CNN mit anschließender Fehlervorhersage über ein FCNN im Rahmen eines MLP-Netzwerkes bestätigt und die generelle Wirksamkeit des entwickelten Konzeptes vor dem Hintergrund der Zielsetzung dieser Arbeit aufgezeigt werden. Die prototypische Umsetzung umfasste weiterhin die Implementierung eines geeigneten Ansatzes zur Ausgestaltung der zweiten selbstlernenden fehlervermeidenden Systemkomponente über Deep Q-Learning und stellt damit eine Referenzarchitektur für die Ausgestaltung eines Konzeptes zur selbstlernenden Fehlervermeidung automatisierter Montagesysteme im Produktionsanlauf der Fahrzeugproduktion zur Verfügung. Die Umsetzung des Gesamtsystems im Rahmen der prototypischen Umsetzung zeigt, dass eine signifikante selbstlernende Fehlervermeidung unter Berücksichtigung externer Einflussvariablen in einem Produktionsanlaufsszenario über das entwickelte Konzept technisch möglich ist.

Im Rahmen einer anschließenden Validierung der erhobenen Versuchsdaten und Ergebnisse kann weiterhin die generelle Eignung des Konzeptes und Stabilität der gemachten Ergebnisse für automatisierte Montageprozessanlagen bestätigt werden.

Das in dieser Arbeit entwickelte und prototypisch umgesetzte Konzept wurde im Speziellen vor dem Hintergrund eines steigenden Automatisierungsgrades im Umfeld der Automobilendmontage entwickelt. Es eignet sich dabei zur generellen Anwendung in Anlaufprozessen der kraftsensitiven Montage von Bauteilen, welche über ein Verrasten befestigt werden. Generell ist jedoch eine Erweiterung des entwickelten Konzeptes auf weitere produzierende Anwendungsbereiche denkbar. Der in dieser Arbeit entwickelte Ansatz konnte zwar die generelle Eignung datengetriebener Lernverfahren aus dem Umfeld des Supervised Machine Learning sowie Reinforcement Learning aufzeigen, eine Übertragbarkeit auf weitere produzierende Anwendungsbereiche verlangt jedoch eine erneute Erprobung und eine eventuelle wissenschaftliche Erweiterung des existierenden Konzeptes für das bisher nicht betrachtete Umfeld.

Weiterhin scheint die etablierte empirische Parametrierung der zur Verfügung stehenden Algorithmen nur bedingt praktikabel für die Ausgestaltung einer selbstlernenden Störungsrobustheit automatisierter Montagesysteme. In Zukunft werden hier Systeme zur eigenständigen Parametrierung benötigt.

Weitere Forschungsbedarfe zeigen sich insbesondere für die Auswahl der notwendigen Eingangsgrößen. Der in dieser Arbeit gewählte Ansatz eines Expertenworkshops liefert erste gute Ergebnisse, gleichzeitig konnte jedoch über die in Kapitel 5.3.2 vorgestellte Systematik einer Dimensionsreduzierung über Expertenwissen keine Verbesserung der Fehlervorhersageeigenschaft erreicht werden. Im Umfeld neuartiger und komplexer automatisierter Montageprozesse erscheint der Ansatz einer allumfänglichen Wahrnehmung automatisierter Montagesysteme somit zielführender. An einer existierenden Systematik zur Auswahl geeigneter Sensorkonzepte und Einflussdaten mangelt es jedoch noch.

## 9 Literaturverzeichnis

### **Abdi und Williams 2010**

Abdi, Hervé; Williams, Lynne J. (2010): Principal component analysis. In: *Wiley interdisciplinary reviews: computational statistics* 2 (4), S. 433–459.

### **Abele et al. 2003**

Abele, Eberhard; Elzenheimer, Jens; Rüstig, Alexander (2003): Anlaufmanagement in der Serienproduktion. In: *ZWF* 98 (4), S. 172–176. DOI: 10.3139/104.100630.

### **Abele und Reinhart 2011**

Abele, Eberhard; Reinhart, Gunther (2011): Zukunft der Produktion. Herausforderungen, Forschungsfelder, Chancen. s.l.: Carl Hanser Fachbuchverlag. Online verfügbar unter <http://www.hanser-elibrary.com/action/showBook?doi=10.3139/9783446428058>.

### **Almgren 1999a**

Almgren, Henrik (1999): Start-up of advanced manufacturing systems—a case study. In: *Integrated Manufacturing Systems* 10 (3), S. 126–136.

### **Almgren 1999b**

Almgren, Henrik (1999): Towards a framework for analyzing efficiency during start-up. In: *International Journal of Production Economics* 60-61, S. 79–86. DOI: 10.1016/S0925-5273(98)00189-3.

### **Alpaydin 2014**

Alpaydin, Ethem (2014): Introduction to machine learning. Third edition: The MIT Press (Adaptive computation and machine learning).

**Aoki-Kinoshita 2008**

Aoki-Kinoshita, Kiyoko F. (2008): An introduction to bioinformatics for glycomics research. In: *PLoS computational biology* 4 (5), e1000075. DOI: 10.1371/journal.pcbi.1000075.

**Basheer und Hajmeer 2000**

Basheer, I. A.; Hajmeer, M. (2000): Artificial neural networks: fundamentals, computing, design, and application. In: *Journal of microbiological methods* 43 (1), S. 3–31.

**Basse et al. 2014**

Basse, Isabel; Schmitt, Sebastian; Gartzten, Thomas; Schmitt, Robert (2014): Solution Principles for Managing Instabilities in Ramp-up. In: *Procedia CIRP* 20, S. 93–97. DOI: 10.1016/j.procir.2014.03.154.

**Bauer et al. 2014**

Bauer, W.; Ganschar, O.; Pokorni, B.; Schlund, S. (2014): Concept of a Failures Management Assistance System for the Reaction on Unforeseeable Events during the Ramp-up. In: *Procedia CIRP* 25, S. 420–425. DOI: 10.1016/j.procir.2014.10.058.

**Bauernhansl et al. 2014**

Bauernhansl, Thomas; Hompel, Michael ten; Vogel-Heuser, Birgit (Hg.) (2014): Industrie 4.0 in Produktion, Automatisierung und Logistik. Anwendung, Technologien, Migration. Wiesbaden: Springer Vieweg (SpringerLink). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-658-04682-8>.

**Ben-Hur und Weston 2010**

Ben-Hur, Asa; Weston, Jason (2010): A user's guide to support vector machines. In: *Data mining techniques for the life sciences*, S. 223–239.

**Benz 2004**

Benz, Axel (2004): Entwicklung einer softwareunterstützten Methode für die statistische Prozesssteuerung beim Produktionslauf. Heimsheim: Jost-Jetter (IPA-IAO-Forschung und -Praxis, Nr. 397).

**Bettenhausen und Kowalewski 2013**

Bettenhausen, Kurt D.; Kowalewski, Stefan (2013): Cyber-Physical Systems: Chancen und Nutzen aus Sicht der Automation. In: *Thesen und Handlungsfelder; VDI/VDE-Gesellschaft Mess- und Automatisierungstechnik: Düsseldorf, Germany*.

**Bischoff 2007**

Bischoff, Raphael (2007): Anlaufmanagement: Schnittstelle zwischen Projekt und Serie. Konstanz: Hochschule Konstanz (Konstanzer Managementschriften, 2). Online verfügbar unter [http://opus.htwg-konstanz.de/files/76/Anlaufmanagement\\_e\\_book\\_070301.pdf](http://opus.htwg-konstanz.de/files/76/Anlaufmanagement_e_book_070301.pdf).

**Bix et al. 2016**

Bix, Johannes; Kossmann, Max; Schmiedel, Ingo (2016): Roboterwerkzeug zum Setzen von Stopfen. Angemeldet durch BAYRISCHE MOTREN WERKE AG am 11.03.2016.

Anmeldenr: 2016055217. Veröffentlichungsnr: WO002016173756A1.

**Bockholt 2012**

Bockholt, Felix (2012): Operatives Störungsmanagement für globale Logistiknetzwerke. Ökonomie- und ökologieorientiertes Referenzmodell für den Einsatz in der Automobilindustrie. Zugl.: Dortmund, Techn. Univ., Diss., 2011. Dortmund: Verl. Praxiswissen (Unternehmenslogistik).

**Bohn und Terwiesch 1999**

Bohn, R.; Terwiesch, C. (1999): The economics of yield-driven processes. In: *Journal of Operations Management* 18 (1), S. 41–59. DOI: 10.1016/S0272-6963(99)00014-5.

**Boysen 2005**

Boysen, Nils (2005): Variantenfließfertigung. Zugl.: Hamburg, Univ., FB Wirtschaftswiss., Diss., 2005. 1. Aufl. Wiesbaden: Dt. Univ.-Verl. (Betriebswirtschaftliche Forschung zur Unternehmensführung, 49).

**Boysen 2007**

Boysen, Nils (2007): Produktionsplanung bei Variantenfließfertigung. In: Karl-Heinz Waldmann und Ulrike M. Stocker (Hg.): *Operations Research Proceedings 2006. Selected Papers of the Annual International Conference of the German Operations Research Society (GOR)*. 1. Aufl. s.l.: Springer-Verlag (Operations Research Proceedings, v.2006), S. 11–15.

**Brecher et al. 2011**

Brecher, Christian; Kozielski, Stefan; Schapp, Lutz (2011): Integrative Produktionstechnik für Hochlohnländer. In: Christian Brecher (Hg.): *Integrative Produktionstechnik für Hochlohnländer*. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg (VDI-Buch), S. 47–70. Online verfügbar unter [https://doi.org/10.1007/978-3-642-20204-9\\_4](https://doi.org/10.1007/978-3-642-20204-9_4).

**Bürgel et al. 1996**

Bürgel, Hans Dietmar; Haller, Christine; Binder, Markus (1996): F-&-E-Management. München: Vahlen.

**Burghardt 2000**

Burghardt, Manfred (2000): Projektmanagement. Leitfaden für die Planung, Überwachung und Steuerung von Entwicklungsprojekten. 5. Aufl. Erlangen: Publicis-MCD-Verl. Online verfügbar unter <http://www.loc.gov/catdir/enhancements/fy0707/2001385506-d.html>.

**Bußwolder et al. 2016**

Bußwolder, Peter; Burgahn, Friedrich; Hübner, Marcel; Werker, Markus (2016): Classification of Company-specific Influence Factors as Part of a Knowledge Management System for Ramp-up Projects. In: *Procedia CIRP* 51, S. 44–50. DOI: 10.1016/j.procir.2016.05.042.

**Chiang et al. 2001**

Chiang, Leo H.; Russell, Evan; Braatz, Richard D. (2001): Fault detection and diagnosis in industrial systems. London u.a.: Springer (Advanced textbooks in control and signal processing).

**Claussen 2012**

Claussen, Peter (2012): Die Fabrik als soziales System. Wandlungsfähigkeit durch systemische Fabrikplanung und Organisationsentwicklung - ein Beispiel aus der Automobilindustrie. Wiesbaden: Springer. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-8349-4377-4>.

**Dembczynski et al. 2013**

Dembczynski, Krzysztof; Jachnik, Arkadiusz; Kotlowski, Wojciech; Waegeman, Willem; Hüllermeier, Eyke (Hg.) 2013 (2013): Optimizing the F-measure in multi-label classification: Plug-in rule approach versus structured loss minimization.

**Deuse et al. 2007**

Deuse, Jochen; Stausberg, Jan Robert; Wischniewski, Sascha (2007): Leitsätze zur Gestaltung einer verschwendungsarmen Produktion. In: *ZWF* 102 (5), S. 291–294. DOI: 10.3139/104.101140.

**Diez 2015**

Diez, Willi (2015): Automobil-Marketing. Erfolgreiche Strategien, praxisorientierte Konzepte, effektive Instrumente. 6., vollständig überarbeitete Auflage. München: Verlag

Franz Vahlen. Online verfügbar unter <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&AN=1056181>.

**Dill 2003**

Dill, Christoph (2003): Turbulenzreaktionsprozesse: Ein Ansatz zur Steigerung der Reaktionsfähigkeit auf Turbulenzen am Beispiel des Produktionshochlaufs. Dissertation. KIT, Karlsruhe. Institut für Produktionstechnik (WBK).

**Doya 2000**

Doya, Kenji (2000): Reinforcement learning in continuous time and space. In: *Neural computation* 12 (1), S. 219–245.

**Drath 2010**

Drath, Rainer (Hg.) (2010): Datenaustausch in der Anlagenplanung mit AutomationML. Integration von CAEX, PLCopen XML und COLLADA. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg (VDI-Buch). Online verfügbar unter <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10358615>.

**Engelhardt 2015**

Engelhardt, Philipp Ronald (2015): System für die RFID-gestützte situationsbasierte Produktionssteuerung in der auftragsbezogenen Fertigung und Montage. Zugl.: München, Techn. Univ., Fak. für Maschinenwesen, Diss., 2015. München: Utz (Forschungsberichte IWB / Institut für Werkzeugmaschinen und Betriebswissenschaften, Technische Universität München, 299). Online verfügbar unter <http://mediatum.ub.tum.de/node?id=1229653>.

**Ennen et al. 2016**

Ennen, Philipp; Reuter, Sebastian; Vossen, Rene; Jeschke, Sabina (2016): Automated Production Ramp-up Through Self-Learning Systems (51). In: *3rd ICRM 2016 International Conference on Ramp-Up Management*, 01.01.2016, S. 57–62.

**Färber 1980**

Färber, G. (1980): Editorial. Prozeßrechner für die Automatisierungssysteme der 80er Jahre. In: *it - Information Technology* 22 (5). DOI: 10.1524/itit.1980.22.16.207.

**Fitzek 2006**

Fitzek, Daniel (2006): Anlaufmanagement in Netzwerken. Grundlagen, Erfolgsfaktoren und Gestaltungsempfehlungen für die Automobilindustrie. Zugl.: St. Gallen, Univ., Diss, 2005. 1. Aufl. Bern: Haupt (Schriftenreihe Logistik der Kühne-Stiftung, 8).

**Fjällström et al. 2009**

Fjällström, Sabina; Säfsten, Kristina; Harlin, Ulrika; Stahre, Johan (2009): Information enabling production ramp-up. In: *Journal of Manufacturing Technology Management* 20 (2), S. 178–196. DOI: 10.1108/17410380910929619.

**Fleischer et al. 2003**

Fleischer, J.; Spath, D.; Lanza, G. (Hg.) 2003 (2003): Quality simulation for fast ramp up. 36th CIRP International Seminar on Manufacturing Systems. Saarland, Germany (6).

**Fleischer et al. 2004**

Fleischer, Jürgen; Wawerla, Marc; Nyhuis, Peter; Winkler, Helge; Liestmann, Volker (2004): Proaktive Anlaufsteuerung von Produktionssystemen entlang der Wertschöpfungskette. In: *Industrie Management* 20 (4), S. 29–32.

**Fleischer et al. 2007**

Fleischer, Jürgen; Nyhuis, Peter; Schuh, Günther; Serwotka, Peter (Hg.) (2007): Proaktive Anlaufsteuerung entlang der Wertschöpfungskette von Produktionssystemen (ProactAS). Unter Mitarbeit von produktiobs. Frankfurt am Main: VDMA-Verl. (Schneller Produktionsanlauf in der Wertschöpfungskette, ; Bd. 4,1).

**Franzkoch und Gottschalk 2008**

Franzkoch, Bastian; Gottschalk, Sebastian (2008): Anlauforganisation. In: Günther Schuh, Wolfgang Stölzle und Frank Straube (Hg.): Anlaufmanagement in der Automobilindustrie erfolgreich umsetzen. Ein Leitfaden für die Praxis. Berlin, Heidelberg: Springer (VDI-Buch), S. 55–64.

**Fritz 2007**

Fritz, Jürgen Ulrich (2007): Zielführende Modellierung und Analyse schlanker Fertigungssysteme mit der digitalen Fabrik. Zugl.: Saarbrücken, Univ., Diss, 2007. Saarbrücken: LFT Lehrstuhl für Fertigungstechnik/CAM (Schriftenreihe Produktionstechnik, 41). Online verfügbar unter [http://scidok.sulb.uni-saarland.de/volltexte/2007/1258/pdf/Dissertation\\_Juergen\\_Fritz.pdf](http://scidok.sulb.uni-saarland.de/volltexte/2007/1258/pdf/Dissertation_Juergen_Fritz.pdf).

**Gardner und Dorling 1998**

Gardner, M.W; Dorling, S.R (1998): Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. In: *Atmospheric Environment* 32 (14-15), S. 2627–2636. DOI: 10.1016/S1352-2310(97)00447-0.

**Geisberger und Broy 2012**

Geisberger, Eva; Broy, Manfred (2012): agendaCPS. Integrierte Forschungsagenda Cyber-Physical Systems. Berlin, Heidelberg: Springer (acatech STUDIE, März 2012, 1). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-642-29099-2>.

**Gentner 1994**

Gentner, Andreas (1994): Entwurf eines Kennzahlensystems zur Effektivitäts- und Effizienzsteigerung von Entwicklungsprojekten. Dargestellt am Beispiel der Entwicklungs- und Anlaufphasen in der Automobilindustrie. Zugl.: Stuttgart, Univ., Diss. München: Vahlen (Controlling-Praxis).

**Gerster 2015**

Gerster, Michael (2015): Daimler stößt mit Produktion an Grenzen. Hg. v. Stuttgarter Nachrichten. Online verfügbar unter <http://www.stuttgarter-nachrichten.de/inhalt.mercedes-produktionschef-daimler-stoesst-mit-produktion-an-grenzen.3abadefd-7fa9-4078-a8ec-11274011130e.html>, zuletzt geprüft am 30.10.2017.

**Ghosh et al. 2006**

Ghosh, Anarta; Biehl, Michael; Hammer, Barbara (2006): Performance analysis of LVQ algorithms: a statistical physics approach. In: *Neural networks* 19 (6), S. 817–829.

**Glock et al. 2012**

Glock, Christoph H.; Jaber, Mohamad Y.; Zolfaghari, Saeed (2012): Production planning for a ramp-up process with learning in production and growth in demand. In: *International Journal of Production Research* 50 (20), S. 5707–5718.

**Golbert und Lewin 2004**

Golbert, Joshua; Lewin, Daniel R. (2004): Model-based control of fuel cells. In: *Journal of Power Sources* 135 (1-2), S. 135–151. DOI: 10.1016/j.jpowsour.2004.04.008.

**Goodfellow et al. 2016**

Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron (2016): Deep learning: MIT press.

**Gronau 2008**

Gronau, Norbert (Hg.) (2008): Wettbewerbsfähigkeit durch Arbeits- und Betriebsorganisation. [20. Forschungsseminar der Hochschulgruppe Arbeits- und Betriebsorganisation (HAB); Tagungsband]. Berlin: GITO-Verl. (Schriftenreihe der Hochschulgruppe für Arbeits- und Betriebsorganisation e.V. (HAB)).

**Hammer und Villmann 2002**

Hammer, Barbara; Villmann, Thomas (2002): Generalized relevance learning vector quantization. In: *Neural networks* 15 (8), S. 1059–1068.

**Hearst et al. 1998**

Hearst, Marti A.; Dumais, Susan T.; Osuna, Edgar; Platt, John; Scholkopf, Bernhard (1998): Support vector machines. In: *IEEE Intelligent Systems and their applications* 13 (4), S. 18–28.

**Heinrich et al. 2015**

Heinrich, Berthold; Linke, Petra; Glöckler, Michael (2015): Grundlagen Automatisierung. Sensorik, Regelung, Steuerung. Wiesbaden: Springer Fachmedien Wiesbaden. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-658-05961-3>.

**Heise 2010**

Heise, Dipl.-Ing. Wolfgang (2010): Das kleine 1 x 1 von zuverlässigkeit und lcc: Lulu Com.

**Hsu et al. 2003**

Hsu, Chih-Wei; Chang, Chih-Chung; Lin, Chih-Jen (2003): A practical guide to support vector classification. Online verfügbar unter <http://www.csie.ntu.edu.tw/~cjlin/papers.html>, zuletzt geprüft am 05.12.2017.

**Huber 2016**

Huber, Walter (2016): Industrie 4.0 in der Automobilproduktion. Ein Praxisbuch. Wiesbaden: Springer Vieweg. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-658-12732-9>.

**Hyvärinen 1997**

Hyvärinen, Aapo (1997): Independent component analysis by minimization of mutual information. Espoo: Helsinki University of Technology (Report / Helsinki University of Technology, Department of Computer Science and Engineering, Laboratory of Computer and Information Science. A, 46).

**Jain et al. 1996**

Jain, Anil K.; Mao, Jianchang; Mohiuddin, K. Moidin (1996): Artificial neural networks: A tutorial. In: *Computer* 29 (3), S. 31–44.

**Jolliffe 2002**

Jolliffe, I. T. (2002): Principal Component Analysis. Second Edition. New York, NY:

Springer-Verlag New York Inc (Springer Series in Statistics). Online verfügbar unter <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10047693>.

**Juering und Milling 2005**

Juering, J.; Milling, P. M. (Hg.) 2005 (2005): Interdependencies of product development decisions and the production ramp-up. The 23rd International Conference of the System Dynamics Society, Boston, MA, USA.

**Juzek 2014**

Juzek, Christian (2014): Entwicklung eines automatisierten, ontologiegestützten Wissensmanagementmodells für Produktionsanläufe in der Automobilindustrie. Zugl.: Cottbus-Senftenberg, Techn. Univ., Diss., 2014. Aachen: Shaker (Berichte aus dem Lehrstuhl Automatisierungstechnik BTU Cottbus-Senftenberg).

**Karl et al. 2011**

Karl, F.; Pohl, J.; Schindler, S. (2011): Umfrage - Beeinflussung der Produktion durch Zyklen. In: *iwb Newsletter* 4 (12), S. 7–8.

**Keller 2017**

Keller, Sebastian (2017): Entwicklung eines wissensbasierten Assistenzsystems zur Konfiguration robotergestützter, hybrider Montagesysteme unter Berücksichtigung sicherheitsrelevanter Anforderungen. 1. Auflage. Herzogenrath: Shaker (Berichte aus dem Lehrstuhl Automatisierungstechnik BTU Cottbus).

**Keller und Schönherr 2017**

Keller, Sebastian; Schönherr, Ralf (2017): Entwicklung von Assistenzsystemen zur Konfiguration, Planung und erfolgreichen Umsetzung innovativer, roboterbasierter Montageanlagen. In: *13. Fachtagung „Digital Engineering technischer Systeme – der Weg zur Smart Factory“*.

**Kleinhenz et al. 2006**

Kleinhenz, Gerhard; Heblich, Stephan; Gold, Robert (2006): Das BMW-Werk Regensburg: wirtschaftliche und soziale Vernetzung in der Region: Wiss.-Verlag Rothe.

**Kohler 2008**

Kohler, Ulrich (2008): Methodik zur kontinuierlichen und kostenorientierten Planung produktionstechnischer Systeme. Zugl.: München, Techn. Univ., Diss., 2007. München: Utz (Forschungsberichte / IWB, 210).

**Kohonen 1995**

Kohonen, Teuvo (1995): Learning Vector Quantization. In: Teuvo Kohonen (Hg.): Self-Organizing Maps. Berlin, Heidelberg: Springer Berlin Heidelberg (Springer Series in Information Sciences, 30).

**Kohonen 2001**

Kohonen, Teuvo (2001): Self-Organizing Maps. Third Edition. Berlin, Heidelberg: Springer Berlin Heidelberg (Springer Series in Information Sciences, 30).

**Kotsiantis et al. 2007**

Kotsiantis, Sotiris B.; Zaharakis, I.; Pintelas, P. (2007): Supervised machine learning: A review of classification techniques. In: *Informatica* (31), S. 249–268.

**Kowalewski et al. 2014**

Kowalewski, Stefan; Rumpe, Bernhard; Stollenwerk, Andre (2014): Cyber-Physical Systems-eine Herausforderung an die Automatisierungstechnik? In: *arXiv preprint arXiv:1409.0385 Proc. Automation 2012, VDI Berichte 2012, VDI-Verlag*, S. 113–116.

**Kroemer und Kasparick 2014**

Kroemer, Nils; Kasparick, Hans-Peter (2014): Industrie 4.0 – Ein Praxisbericht. In: *ZWF* 109 (1-2), S. 76–79. DOI: 10.3139/104.111093.

**Krüger et al. 2009**

Krüger, J.; Lien, T. K.; Verl, A. (2009): Cooperation of human and machines in assembly lines. In: *CIRP Annals - Manufacturing Technology* 58 (2), S. 628–646. DOI: 10.1016/j.cirp.2009.09.009.

**LeCun et al. 2012**

LeCun, Yann A.; Bottou, Léon; Orr, Genevieve B.; Müller, Klaus-Robert (2012): Efficient backprop. In: *Neural networks: Tricks of the trade*: Springer, S. 9–48.

**Lippe 2006**

Lippe, Wolfram-Manfred (2006): Soft-Computing. Mit Neuronalen Netzen, Fuzzy-Logic und Evolutionären Algorithmen. Berlin Heidelberg: Springer-Verlag Berlin Heidelberg (eXamen.press). Online verfügbar unter <http://dx.doi.org/10.1007/3-540-29274-8>.

**Lödding 2008**

Lödding, Hermann (2008): Verfahren der Fertigungssteuerung. Grundlagen,

Beschreibung, Konfiguration. 2., erw. Aufl. Berlin, Heidelberg: Springer-Verlag (VDI-Buch). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-540-76860-9>.

**Lotter und Wiendahl 2012**

Lotter, Bruno; Wiendahl, Hans-Peter (2012): Montage in der industriellen Produktion. Ein Handbuch für die Praxis. 2. Aufl. 2013. Berlin, Heidelberg: Springer (VDI-Buch). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-642-29061-9>.

**Lunze 2016**

Lunze, Jan (2016): Regelungstechnik 1. Systemtheoretische Grundlagen, Analyse und Entwurf einschleifiger Regelungen. 11., überarbeitete Aufl. 2016. Berlin, Heidelberg: Springer Berlin Heidelberg. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-662-52678-1>.

**Mannar und Ceglarek 2004**

Mannar, K.; Ceglarek, D. (2004): Continuous Failure Diagnosis for Assembly Systems using Rough Set Approach. In: *CIRP Annals - Manufacturing Technology* 53 (1), S. 39–42. DOI: 10.1016/S0007-8506(07)60640-4.

**Matthias et al. 2013**

Matthias, Björn; Ding, Hao; Forschungszentrum, ABBAG (Hg.) 2013 (2013): Die Zukunft der Mensch-Roboter Kollaboration in der industriellen Montage. Conference Paper, Internationales Forum mechatronik.

**McDermott et al. 1996**

McDermott, Robin; Mikulak, Raymond J.; Beauregard, Michael (1996): The basics of FMEA: SteinerBooks.

**Meier und Hormuth 2006**

Meier, H.; Hormuth, M. (2006): Holistic ramp-up management in SME-networks. In: *Proceedings of the 39th International Seminar on Manufacturing Systems, Ljubljana (Slovenien)*, S. 123–128.

**Michalos et al. 2010**

Michalos, G.; Makris, S.; Papakostas, N.; Mourtzis, D.; Chryssolouris, G. (2010): Automotive assembly technologies review. Challenges and outlook for a flexible and adaptive approach. In: *CIRP Journal of Manufacturing Science and Technology* 2 (2), S. 81–91. DOI: 10.1016/j.cirpj.2009.12.001.

**Mnih et al. 2013**

Mnih, Volodymyr; Kavukcuoglu, Koray; Silver, David; Graves, Alex; Antonoglou, Ioannis; Wierstra, Daan; Riedmiller, Martin (2013): Playing atari with deep reinforcement learning. In: *arXiv preprint arXiv:1312.5602*.

**Monostori 2014**

Monostori, László (2014): Cyber-physical Production Systems. Roots, Expectations and R&D Challenges. In: *Procedia CIRP* 17, S. 9–13. DOI: 10.1016/j.procir.2014.03.115.

**Motzer 2015**

Motzer, David (2015): Strukturalternative für die Aggregateaufrüstung einer automobilen Fertigung. Konzeption und Evaluation eines Montagesystems. Zugl.: Pforzheim, Hochsch., Masterarbeit, [2015]. Wiesbaden: Springer Gabler (BestMasters). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-658-08805-7>.

**Mühlhaus et al. 1999**

Mühlhaus, R.; Görner, K.; Pollack, M.; Moll, W.; Pflipsen, K. (1999): Neuronale Netze für die Prozeßoptimierung. In: *VDI-Berichte* Nr. 1495, S. 493–501.

**Murray 1995**

Murray, Alan F. (Hg.) (1995): Applications of Neural Networks. Boston, MA: Springer. Online verfügbar unter <http://dx.doi.org/10.1007/978-1-4757-2379-3>.

**Nagel 2011**

Nagel, Jörg (2011): Risikoorientiertes Anlaufmanagement. Zugl.:Cottbus, Brandenburgische Techn. Univ., Diss., 2010. 1. Aufl. Wiesbaden: Gabler Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden (Beiträge zur Produktionswirtschaft). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-8349-6850-0>.

**Näser und Müller 2008**

Näser, Peggy; Müller, Egon (2008): Steuerung des Anlaufmanagements mit komplexen Regelkreisen. Methode zur Entwicklung und kontinuierlichen Verbesserung des Anlaufmanagements komplexer Montagesysteme. In: *wt Werkstattstechnik online* 98 (4), S. 262–267.

**Nauck et al. 1994**

Nauck, Detlef; Klawonn, Frank; Kruse, Rudolf (1994): Neuronale Netze und Fuzzy-Systeme. Grundlagen des Konnektionismus, neuronaler Fuzzy-Systeme und der Kopplung mit wissensbasierten Methoden. Braunschweig u.a.: Vieweg (Artificial intelligence).

**Oates et al. 2012**

Oates, Robert; Scrimieri, Daniele; Ratchev, Svetan (2012): Accelerated ramp-up of assembly systems through self-learning. In: Svetan Ratchev (Hg.): Precision Assembly Technologies and Systems. 6th IFIP WG 5.5 International Precision Assembly Seminar, IPAS 2012, Chamonix, France, February 12-15, 2012. Proceedings. Berlin, Heidelberg: Springer Berlin Heidelberg (IFIP Advances in Information and Communication Technology, 371), S. 175–182.

**OICA 2016**

OICA, a) (2016): 2016 Production Statistics. Hg. v. Weltverband der Automobilverbände OICA. Online verfügbar unter <http://www.oica.net/category/production-statistics/>Zugriff am: 03.09.2017.

**Ossola-Haring et al. 2016**

Ossola-Haring, Claudia; Schlageter, Andreas; Schöning, Stephan (2016): 11 Irrtümer über Kennzahlen. Mit den richtigen Zahlen führen. Wiesbaden: Springer Gabler. Online verfügbar unter <http://gbv.ebib.com/patron/FullRecord.aspx?p=4527964>.

**Pal und Mitra 1992**

Pal, Sankar K.; Mitra, Sushmita (1992): Multilayer perceptron, fuzzy sets, and classification. In: *IEEE Transactions on neural networks* 3 (5), S. 683–697.

**Parker et al. 1999**

Parker, R. S.; Doyle, F. J.; Peppas, N. A. (1999): A model-based algorithm for blood glucose control in Type I diabetic patients. In: *IEEE Trans. Biomed. Eng.* 46 (2), S. 148–157. DOI: 10.1109/10.740877.

**Pawlak 1982**

Pawlak, Zdzislaw (1982): Rough sets. In: *International Journal of Computer and Information Sciences* 11 (5), S. 341–356. DOI: 10.1007/BF01001956.

**Peters und Hofstetter 2008**

Peters, Nils; Hofstetter, Jörg (2008): Konzepte und Erfolgsfaktoren für Anlaufstrategien in Netzwerken der Automobilindustrie. In: Günther Schuh, Wolfgang Stölzle und Frank Straube (Hg.): Anlaufmanagement in der Automobilindustrie erfolgreich umsetzen. Ein Leitfaden für die Praxis. Berlin, Heidelberg: Springer (VDI-Buch), S. 9–30.

**Pfeifer 1996**

Pfeifer, Tilo (1996): Qualitätsmanagement. Strategien, Methoden, Techniken. 2., vollst. überarb. und erw. Aufl. München: Hanser.

**Poschmann 2000**

Poschmann, Michael (2000): Einsatz neuronaler Netze zur Optimierung der Prozeßführung bei der Blasstrahlerzeugung. Dissertation. Bibliothek der RWTH Aachen.

**Powers 2011**

Powers, David Martin (2011): Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. In: *Journal of Machine Learning Technologies*, S. 37–63.

**Prasch 2010**

Prasch, Martin Georg (2010): Integration leistungsgewandelter Mitarbeiter in die variantenreiche Serienmontage. Zugl.: München, Techn. Univ., Diss., 2010. München: Utz (Forschungsberichte IWB, 243).

**Reinhart 1998**

Reinhart, Gunther (1998): Montage-Management: Lösungen zum Montieren am Standort Deutschland. München: TCW Transfer-Centrum (TCW Report, 6).

**Renner und Dyckhoff 2012**

Renner, Tim; Dyckhoff, Harald (2012): Performance-Management im Produktionsanlauf. Dissertation. Hg. v. RWTH Aachen University 2012. Lehrstuhl für Unternehmenstheorie, insb. Nachhaltige Produktion und Industrielles Controlling.

**Reuter et al. 2014**

Reuter, Sebastian; Ewert, Daniel; Jeschke, Sabina (2014): Facing Ramp-Up Challenges in the RoboCup Logistics League. In: *Proceedings of the 2014 International Conference on Industrial Engineering and Operations Management*.

**Riedmiller 1994**

Riedmiller, Martin (1994): Advanced supervised learning in multi-layer perceptrons— from backpropagation to adaptive learning algorithms. In: *Computer Standards & Interfaces* 16 (3), S. 265–278.

**Risse 2003**

Risse, Jörg (2003): Time-to-Market-Management in der Automobilindustrie. Ein Gestaltungsrahmen für ein logistikorientiertes Anlaufmanagement. Zugl.: Berlin, Techn. Univ., Diss., 2002. Bern, Wien u.a.: Haupt (Schriftenreihe Logistik der Kühne-Stiftung, 4).

**Romberg und Haas 2005**

Romberg, Andreas; Haas, Martin (2005): Der Anlaufmanager. Effizient arbeiten mit Führungssystem und Workflow ; von der Produktidee bis zu Serie. Stuttgart: LOG X.

**Roscher 2008**

Roscher, Jörg (2008): Bewertung von Flexibilitätsstrategien für die Endmontage in der Automobilindustrie. Dissertation: Universität Stuttgart, 2008.

**Rosenblatt 1960**

Rosenblatt, Frank (1960): On the convergence of reinforcement procedures in simple perceptrons (Project Para). Report (Cornell Aeronautical Laboratory): Cornell Aeronautical Laboratory, Inc.

**Schade et al. 2014**

Schade, Wolfgang; Zanker, Christoph; Kühn, André; Hettesheimer, Tim (2014): Sieben Herausforderungen für die deutsche Automobilindustrie. Strategische Antworten im Spannungsfeld von Globalisierung, Produkt- und Dienstleistungsinnovationen bis 2030. 1. Auflage. Baden-Baden: Nomos Verlagsgesellschaft mbH & Co. KG. Online verfügbar unter <http://dx.doi.org/10.5771/9783845270289>.

**Schenk et al. 2014**

Schenk, Michael; Wirth, Siegfried; Müller, Egon (2014): Fabrikplanung und Fabrikbetrieb. Methoden für die wandlungsfähige, vernetzte und ressourceneffiziente Fabrik. 2., vollst. überarb. und erw. Aufl. Berlin: Springer Vieweg (VDI-Buch). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-642-05459-4>.

**Schenk und Elkmann 2012**

Schenk, Michael; Elkmann, Norbert (2012): Sichere Mensch-Roboter-Interaktion : Anforderungen, Voraussetzungen, Szenarien und Lösungsansätze. In: Egon Müller (Hg.): Demographischer Wandel. Herausforderung für die Arbeits- und Betriebsorganisation der Zukunft ; [Tagungsband zum 25. HAB-Forschungsseminar]. Berlin: GITO-Verl. (Schriftenreihe der Hochschulgruppe für Arbeits- und Betriebsorganisation e.V. (HAB)).

**Schindler 2015**

Schindler, Sebastian (2015): Strategische Planung von Technologieketten für die Produktion. Zugl.: München, Techn. Univ., Diss., 2014. München: Utz (Forschungsberichte IWB, 294).

**Schmahls 2001**

Schmahls, Thomas (2001): Beitrag zur Effizienzsteigerung während Produktionsanläufen in der Automobilindustrie. Dissertation: Techn. Univ., Inst. für Betriebswiss. und Fabrikssysteme.

**Schmidhuber 2015**

Schmidhuber, Jürgen (2015): Deep learning in neural networks: An overview. In: *Neural networks* 61, S. 85–117.

**Schmigalla 1995**

Schmigalla, Hans (1995): Fabrikplanung. Begriffe und Zusammenhänge. 1. Aufl. München: Hanser (REFA-Fachbuchreihe Betriebsorganisation).

**Schmitt 2015**

Schmitt, Robert (Hg.) (2015): Anlaufmanagement - Begriffe und Definitionen. Aachen: Apprimus Wissenschaftsverlag.

**Schmitt und Beaujean 2007**

Schmitt, Robert; Beaujean, Patrick (2007): Selbstoptimierende Produktionssysteme: Eine neue Dimension von Flexibilität, Transparenz und Qualität. In: *ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb* 102 (9), S. 520–524.

**Schneider 2010**

Schneider, Petra (2010): Advanced methods for prototype-based classification. Groningen: Atto Producties Europe.

**Schneider und Lücke 2002**

Schneider, Marc; Lücke, Michael (2002): Kooperations und Referenzmodelle für den Anlauf. In: *Schneller Produktionsanlauf von Serienprodukten. wt Werkstattstechnik online* 92 (10).

**Scholz-Reiter und Krohne 2010**

Scholz-Reiter, B.; Krohne, F. (2010): Ramp-Up Excellence. Ein skalierbares Anlaufmanagementprozessmodell für Elektronik Zulieferer. Bremen: BIBA - Bremer Institut für Produktion und Logistik (15072). In: *Schlussbericht zum Forschungsvorhaben*.

**Schönherr et al. 2016**

Schönherr, Ralf; Kossmann, Max; Schmiedel, Ingo (2016): Stapelvorrichtung zum Stapeln von Lack- und Montagestopfen. Angemeldet durch BAYERISCHE MOTOREN WERKE AG am 19.07.2016. Anmeldenr: 2016067197. Veröffentlichungsnr: WO002017041947A1.

**Schröder 2010**

Schröder, Dierk (2010): Intelligente Verfahren. Identifikation und Regelung nichtlinearer Systeme. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-642-11398-7>.

**Schröder 2016**

Schröder, Christoph (2016): Industrielle Arbeitskosten im internationalen Vergleich. In: *IW-Trends–Vierteljahresschrift zur empirischen Wirtschaftsforschung* 43 (3), S. 39–57.

**Schuh et al. 2005**

Schuh, Günther; Desoi, Jens-Christian; Tücks, Gregor (2005): Holistic Approach for Production Ramp-Up in Automotive Industry. In: Alan Bramley, Daniel Brissaud, Daniel Coutellier und Chris McMahon (Hg.): *Advances in integrated design and manufacturing in mechanical engineering*. Dordrecht: Springer, S. 255–268.

**Schuh et al. 2008**

Schuh, Günther; Stölzle, Wolfgang; Straube, Frank (Hg.) (2008): *Anlaufmanagement in der Automobilindustrie erfolgreich umsetzen. Ein Leitfaden für die Praxis*. Berlin, Heidelberg: Springer (VDI-Buch). Online verfügbar unter <http://d-nb.info/989801519/34>.

**Schuh und Stich 2012**

Schuh, Günther; Stich, Volker (Hg.) (2012): *Produktionsplanung und -steuerung 2. Evolution der PPS*. 4., überarb. Aufl. Berlin: Springer (VDI-Buch). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-642-25427-7>.

**Spath et al. 2013**

Spath, Dieter; Ganschar, Oliver; Gerlach, Stefan; Hämmerle, Moritz; Krause, Tobias; Schlund, Sebastian (Hg.) (2013): *Produktionsarbeit der Zukunft - Industrie 4.0*. [Studie]. Fraunhofer-Institut für Arbeitswirtschaft und Organisation. Stuttgart: Fraunhofer-Verl.

**Spinnarke 2017**

Spinnarke, Sabine (2017): So wird Künstliche Intelligenz in der Produktion eingesetzt. Hg. v. Produktion -Technik und Wirtschaft für deutsche Unternehmen. Online verfügbar unter <https://www.produktion.de/trends-innovationen/so-wird-kuenstliche-intelligenz-in-der-produktion-eingesetzt-104.html>, zuletzt geprüft am 11.05.2018.

**Steegmüller und Zürn 2014**

Steegmüller, Dieter; Zürn, Michael (2014): Wandlungsfähige Produktionssysteme für den Automobilbau der Zukunft. In: Thomas Bauernhansl, Michael ten Hompel und Birgit Vogel-Heuser (Hg.): Industrie 4.0 in Produktion, Automatisierung und Logistik. Anwendung, Technologien, Migration. Wiesbaden: Springer Vieweg (SpringerLink), S. 103–119.

**Steinwart und Christmann 2008**

Steinwart, Ingo; Christmann, Andreas (2008): Support vector machines. 1st edition. New York: Springer (Information science and statistics).

**Sterritt 2005**

Sterritt, Roy (2005): Autonomic computing. In: *Innovations Syst Softw Eng* 1 (1), S. 79–88. DOI: 10.1007/s11334-005-0001-5.

**Stocker et al. 2014**

Stocker, Alexander; Brandl, Peter; Michalczuk, Rafael; Rosenberger, Manfred (2014): Mensch-zentrierte IKT-Lösungen in einer Smart Factory. In: *Elektrotech. Inftech.* 131 (7), S. 207–211. DOI: 10.1007/s00502-014-0215-z.

**Straube 2004**

Straube, Frank (2004): e-Logistik. Ganzheitliches Logistikmanagement. Zugl.: St. Gallen, Univ., Habil.-Schr. Berlin: Springer.

**Straube und Fitzek 2005**

Straube, F.; Fitzek, D. (2005): Herausforderungen und Erfolgsfaktoren im Anlaufmanagement der Automobilindustrie. In: *Jahrbuch der Logistik* 2005, S. 44–47.

**Sugiyama 2015**

Sugiyama, Masashi (2015): Statistical reinforcement learning. Modern machine learning approaches. Boca Raton, FL: CRC Press (Chapman & Hall / CRC machine learning & pattern recognition series). Online verfügbar unter <http://proquest.tech.safaribooksonline.de/9781439856895>.

**Surbier et al. 2014**

Surbier, Laurène; Alpan, Gülgün; Blanco, Eric (2014): A comparative study on production ramp-up: state-of-the-art and new challenges. In: *Production Planning & Control* 25 (15), S. 1264–1286.

**Suthaharan 2016**

Suthaharan, Shan (2016): Machine Learning Models and Algorithms for Big Data Classification. Thinking with Examples for Effective Learning. 1st ed. 2016 (Integrated Series in Information Systems). Online verfügbar unter <http://dx.doi.org/10.1007/978-1-4899-7641-3>.

**Svozil et al. 1997**

Svozil, Daniel; Kvasnicka, Vladimir; Pospichal, Jiri (1997): Introduction to multi-layer feed-forward neural networks. In: *Chemometrics and intelligent laboratory systems* 39 (1), S. 43–62.

**Tauber 1990**

Tauber, Alois (1990): Modellbildung kinematischer Strukturen als Komponente der Montageplanung. Berlin, Heidelberg: Springer (iwb Forschungsberichte, Berichte aus dem Institut für Werkzeugmaschinen und Betriebswissenschaften der Technischen Universität München, 30). Online verfügbar unter <http://dx.doi.org/10.1007/978-3-662-08794-7>.

**Terwiesch und E. Bohn 2001**

Terwiesch, Christian; E. Bohn, Roger (2001): Learning and process improvement during production ramp-up. In: *International Journal of Production Economics* 70 (1), S. 1–19. DOI: 10.1016/S0925-5273(00)00045-1.

**Thim und Weber 2012**

Thim, C.; Weber, N. (2012): Herausforderungen des demographischen Wandels an den Transfer von Erfahrungswissen. In: Egon Müller (Hg.): Demographischer Wandel. Herausforderung für die Arbeits- und Betriebsorganisation der Zukunft ; [Tagungsband zum 25. HAB-Forschungsseminar]. Berlin: GITO-Verl. (Schriftenreihe der Hochschulgruppe für Arbeits- und Betriebsorganisation e.V. (HAB)), S. 361–380.

**Tong und Koller 2001**

Tong, Simon; Koller, Daphne (2001): Support vector machine active learning with applications to text classification. In: *Journal of machine learning research* 2 (Nov), S. 45–66.

**Tücks 2010**

Tücks, Gregor (2010): Ramp-Up Management in der Automobilindustrie. Zugl.: Aachen, Techn. Hochsch., Diss., 2009. 1. Aufl. Aachen: Apprimus-Verl. (Ergebnisse aus der Produktionstechnik Produktionssystematik, 2009,13).

**Ulrich 2016**

Ulrich, Sebastian (2016): Umgang mit Störungen im Produktionsanlauf. Dissertation. Josef Eul Verlag GmbH.

**VDI 1990**

VDI, 2860 (1990): Montage- und Handhabungstechnik; Handhabungsfunktionen, Handhabungseinrichtungen; Begriffe, Definitionen, Symbole. Düsseldorf: VDI (VDI-Richtlinien).

**VDI 2009**

VDI, 5200 (2009): Planungsvorgehen. Planning procedures. Berlin: Beuth (VDI-Richtlinien, 5200,1 Entwurf).

**VDI 2011**

VDI, 5200 (2011): VDI-Richtlinie VDI 5200. Planungsvorgehen. Planning procedures. Ausg. deutsch/englisch. Berlin: Beuth (Fabrikplanung, = Factory planning / VDI-Gesellschaft Produktionstechnik (ADB), Fachausschuss Fabrikplanung ; Blatt 1).

**Verworn und Herstatt 2000**

Verworn, Birgit; Herstatt, Cornelius (2000): Modelle des Innovationsprozesses. Working Papers / Technologie- und Innovationsmanagement, Technische Universität Hamburg-Harburg. Hamburg (6). Online verfügbar unter <http://hdl.handle.net/10419/55484>.

**Villmann et al. 2017**

Villmann, Thomas; Bohnsack, Andrea; Kaden, Marika (2017): Can Learning Vector Quantization be an Alternative to SVM and Deep Learning? - Recent Trends and Advanced Variants of Learning Vector Quantization for Classification Learning. In: *Journal of Artificial Intelligence and Soft Computing Research* 7 (1). DOI: 10.1515/jaiscr-2017-0005.

**Warnecke 1984**

Warnecke, Hans-Jürgen (1984): Der Produktionsbetrieb. Eine Industriebetriebslehre für Ingenieure. Berlin, Heidelberg, s.l.: Springer Berlin Heidelberg. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-662-06541-9>.

**Weber 2002**

Weber, G. (2002): Die Automobilmontage im Umbruch – Anlaufmanagement/Ramp up. Bad Nauheim: Technik & Kommunikation Verlags GmbH Berlin (tci), 03.06.2002.

**Werner 2009**

Werner, Jochen (2009): Methode zur roboterbasierten förderbandsynchronen Fließmontage am Beispiel der Automobilindustrie. Zugl.: München, Techn. Univ., Diss., 2008. München: Utz (Forschungsberichte IWB, 225). Online verfügbar unter <http://classificationweb.net/min/mina-ret?app=Class&auto=1&menu=/Auto/&mod=Browser&time=1253884457>.

**Westkämper 2013**

Westkämper, Engelbert (Hg.) (2013): Montageplanung - effizient und marktgerecht. Softcover repr. of the hardcover 1st ed. 2001. Berlin: Springer (VDI-Buch).

**Widrow und Lehr 1990**

Widrow, Bernard; Lehr, Michael A. (1990): 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. In: *Proceedings of the IEEE* 78 (9), S. 1415–1442.

**Wiendahl et al. 2002**

Wiendahl, Hans-Peter; Hegenscheidt, Matthias; Winkler, Helge (2002): Anlaufrobuste Produktionssysteme. In: *wt Werkstattstechnik online* 92 (11/12), S. 650–655.

**Wildemann 2004**

Wildemann, Horst (2004): Präventive Handlungsstrategien für den Produktionsanlauf. In: *Industrie Management* 20 (4), S. 17–20.

**Wildemann 2006**

Wildemann, Horst (2006): Anlaufmanagement. Leitfaden zur Verkürzung der Hochlaufzeit und Optimierung der An- und Auslaufphase von Produkten. 4. Aufl. München: TCW Transfer-Centrum GmbH & Co. KG (Leitfaden / TCW, Transfer-Centrum für Produktions-Logistik und Technologiemanagement, 76).

**Wildemann 2015**

Wildemann, Horst (2015): Anlaufmanagement. Leitfaden zur Optimierung der Anlaufphase von Produkten, Anlagen und Dienstleistungen ; [Leitfaden zur Verkürzung der Hochlaufzeit und Optimierung der An- und Auslaufphase von Produkten]. 14. Aufl. München: TCW Transfer-Centrum (Leitfaden / TCW, Transfer-Centrum für Produktions-Logistik und Technologie-Management, 76).

**Winkler et al. 2007**

Winkler, Helge; Heins, Michael; Nyhuis, Peter (2007): A controlling system based on cause–effect relationships for the ramp-up of production systems. In: *Prod. Eng. Res. Devel.* 1 (1), S. 103–111. DOI: 10.1007/s11740-007-0011-2.

**Wold et al. 1987**

Wold, Svante; Esbensen, Kim; Geladi, Paul (1987): Principal component analysis. In: *Chemometrics and intelligent laboratory systems 2* (1-3), S. 37–52.

**Wolgast und Carlson 2007**

Wolgast, A.; Carlson, B. E. (Hg.) 2007 (2007): Running changes and re-design in the auto industry: An exploratory study of engineering and knowledge transfer after start of production. Proceedings of 30th Information Systems Research Seminar in Scandinavia–IRIS30. Tampere, Finland (14.8).

**Yager und Zadeh 1992**

Yager, Ronald R.; Zadeh, Lotfi A. (Hg.) (1992): An Introduction to Fuzzy Logic Applications in Intelligent Systems. Boston, MA: Springer (The Springer International Series in Engineering and Computer Science, Knowledge Representation, Learning and Expert Systems, 165). Online verfügbar unter <http://dx.doi.org/10.1007/978-1-4615-3640-6>.

**Yan 2014**

Yan, Jihong (2014): Machinery prognostics and prognosis oriented maintenance management. 1. Aufl. Singapore: Wiley.

**Zacher und Reuter 2011**

Zacher, Serge; Reuter, Manfred (2011): Regelungstechnik für Ingenieure. Analyse, Simulation und Entwurf von Regelkreisen. 13., überarb. und erw. Aufl. Wiesbaden: Vieweg+Teubner Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden. Online verfügbar unter <http://dx.doi.org/10.1007/978-3-8348-9837-1>.

**Zhang 2000**

Zhang, Guoqiang Peter (2000): Neural networks for classification: a survey. In: *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 30 (4), S. 451–462.

## 10 Studienarbeiten

Im Rahmen der Entstehung der vorliegenden Arbeit wurden folgenden Studienarbeiten durch den Autor betreut. Wertvolle Informationen und Erkenntnisse sind hieraus in Teilen in die vorliegende Arbeit eingegangen. Der Autor dankt allen Studierenden für ihr Engagement, die Mühen und die stets gute Zusammenarbeit bei der Unterstützung dieser wissenschaftlichen Arbeit.

Ein weiterer besonderer Dank gilt Herrn Maximilian Knaller, der im Rahmen eines studentischen Praktikums bei der Konzeptionierung und technischen Realisierung der Versuchsanlage stark unterstützt hat.

Die Auflistung der Studienarbeiten erfolgt alphabetisch anhand des Nachnamens der Autoren.

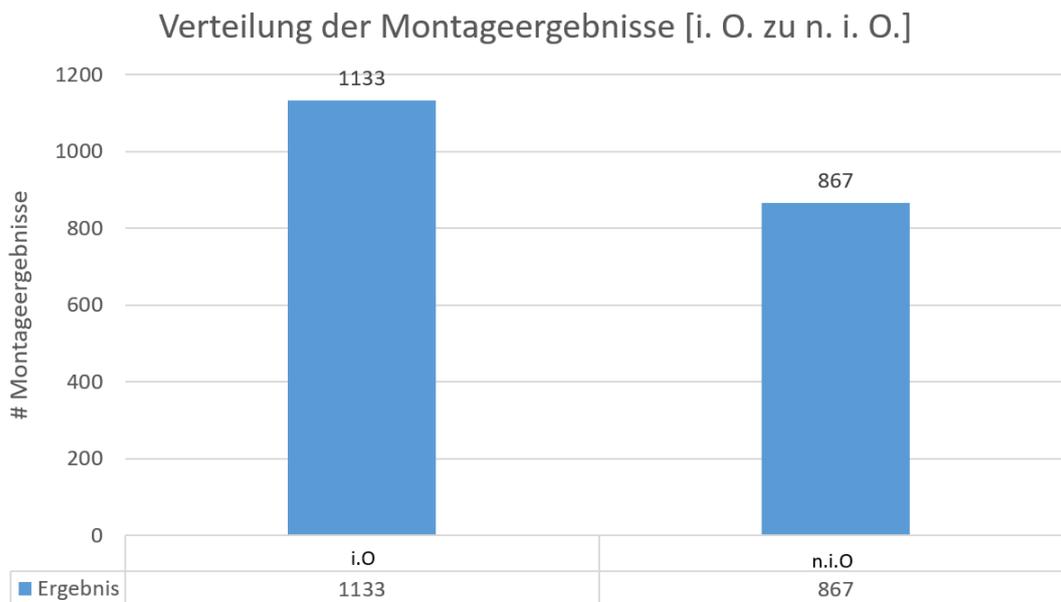
Studierender	Studienarbeit
Buchner, Markus	Bewertung des Einsatzes von Smart Data zur Unterstützung neuer hybrider Montageeinrichtungen im Produktionsanlauf.  Universität Bayreuth, 03/2017
Burseg, Lukas	Entwicklung eines MRK-fähigen Linearachssystems zur Integration sensibler Leichtbaurobotik in die kontinuierlich bewegte Fahrzeugendmontage.  Hochschule für angewandte Wissenschaft München, 08/2017

Boeswald, Christopher	Anforderungsbasierte Analyse und Bewertung verfügbarer Sensortechnologien zur Anwendung in Mensch-Roboter-Kollaborations-Systemen.  Hochschule Augsburg, 09/2017
Ferretiz, Carlos	Automation of Simple Manual Processes by Means of an Industrial Robot 's Force Sensibility.  Hochschule Rosenheim, 01/2017
Han, Longfei	Anwendung neuronaler Netzwerke und Support Vector Machines zur Vorhersage von Fehlern im Anlaufprozess innovativer Anlagentechnik  KIT Karlsruhe, 09/2017

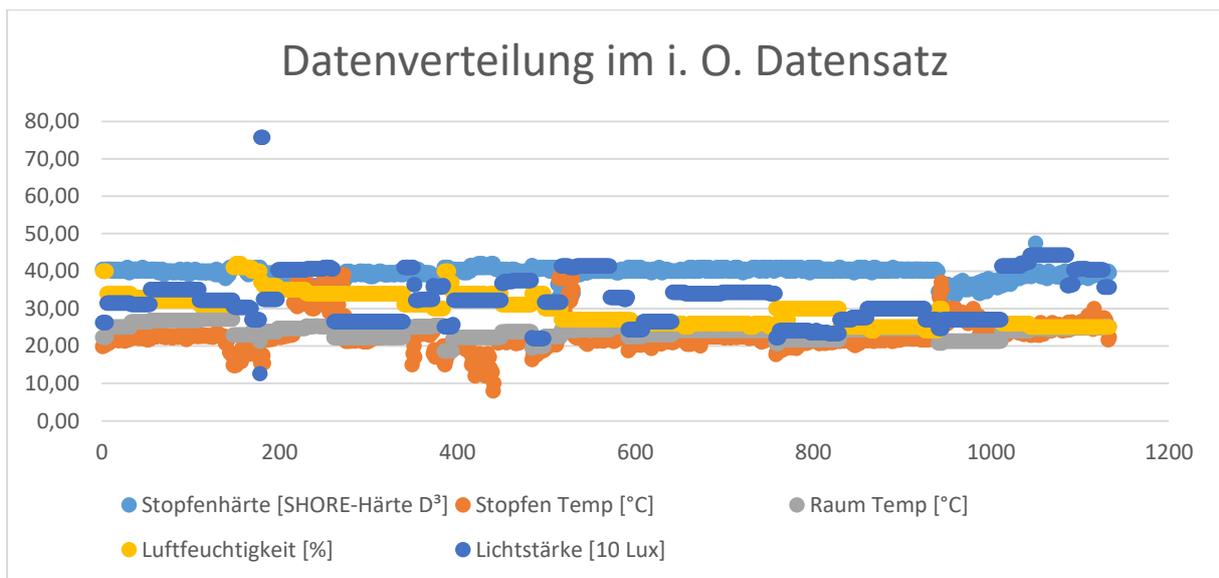
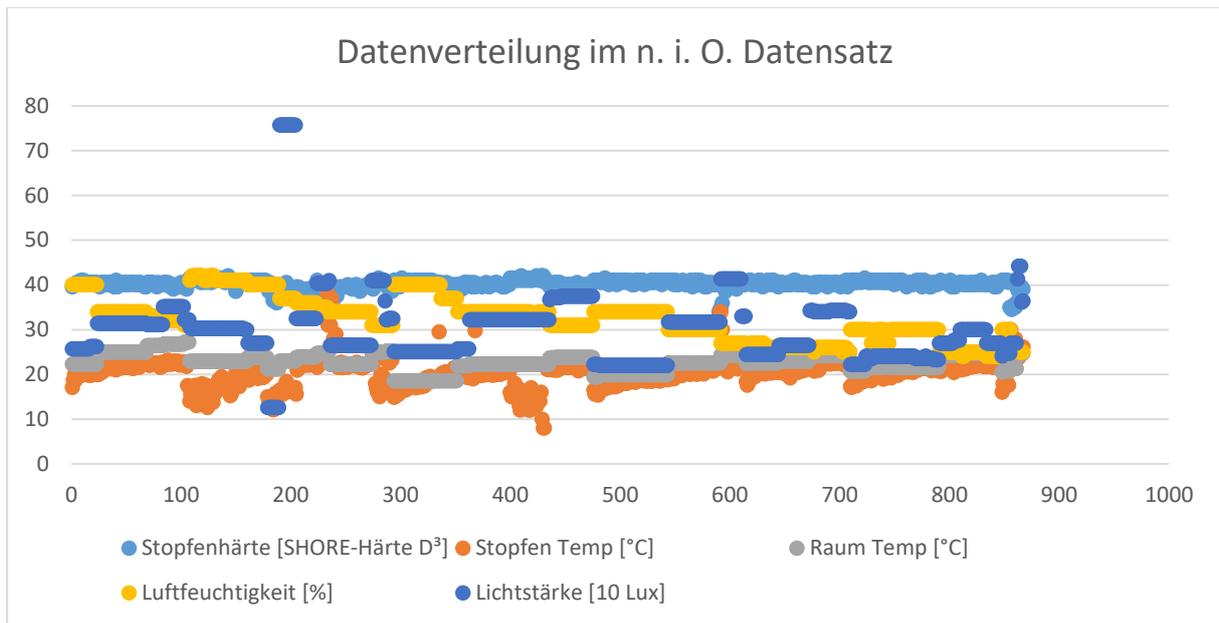
# 11 Anhang

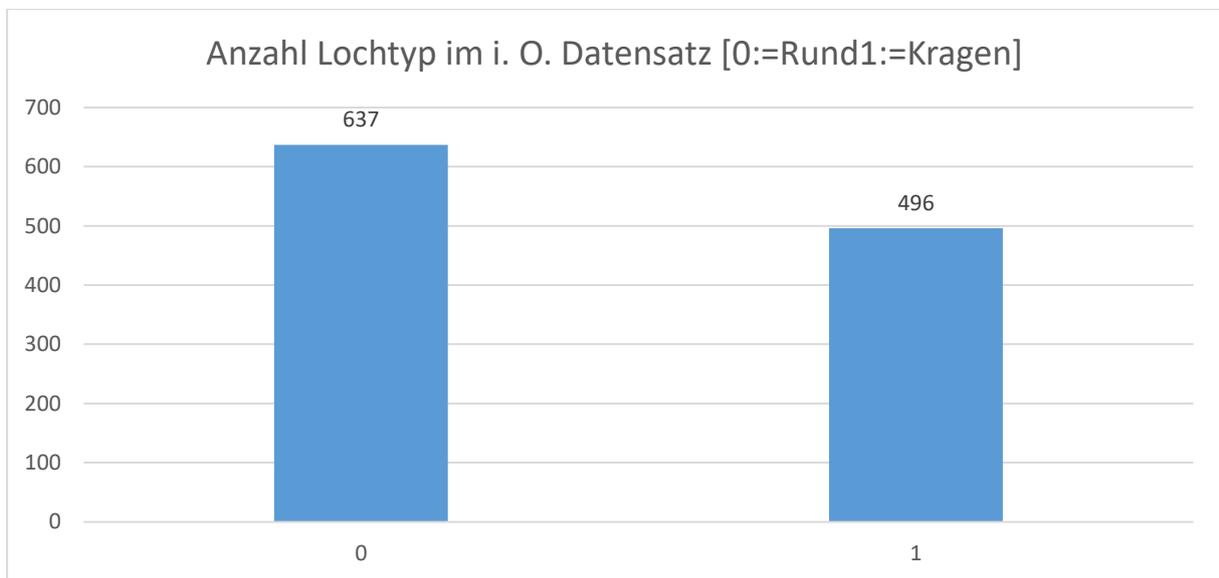
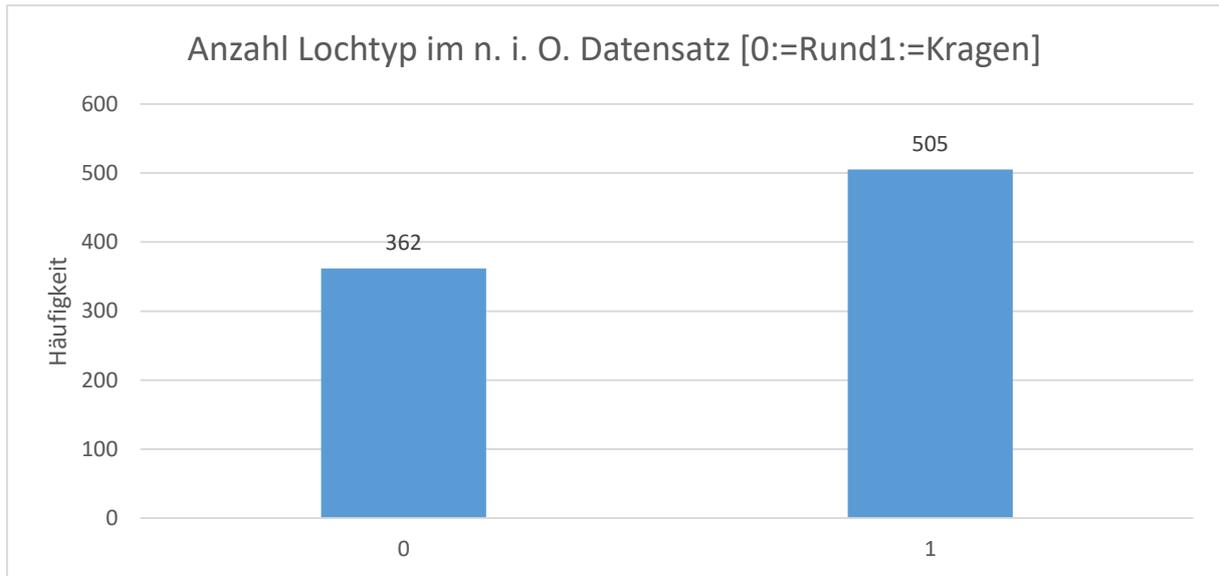
## A: Erhobene Versuchdaten (exklusive Bilddaten der Vorladeposition)

Verteilung der Montageergebnisse in den erhobenen 2000 Versuchsdatensets.



Überblick der i. O. / n. i. O. Datenverteilungen





## B: Schwinungsuntersuchungen in Realumgebung

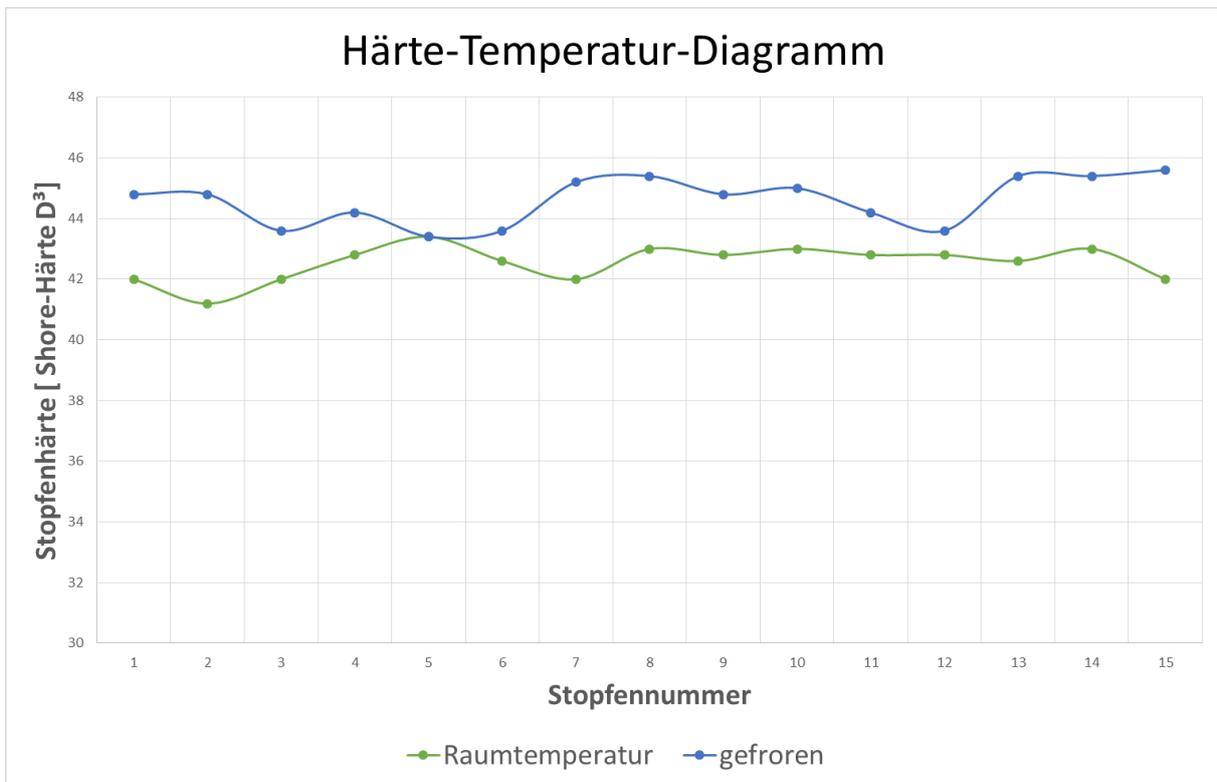
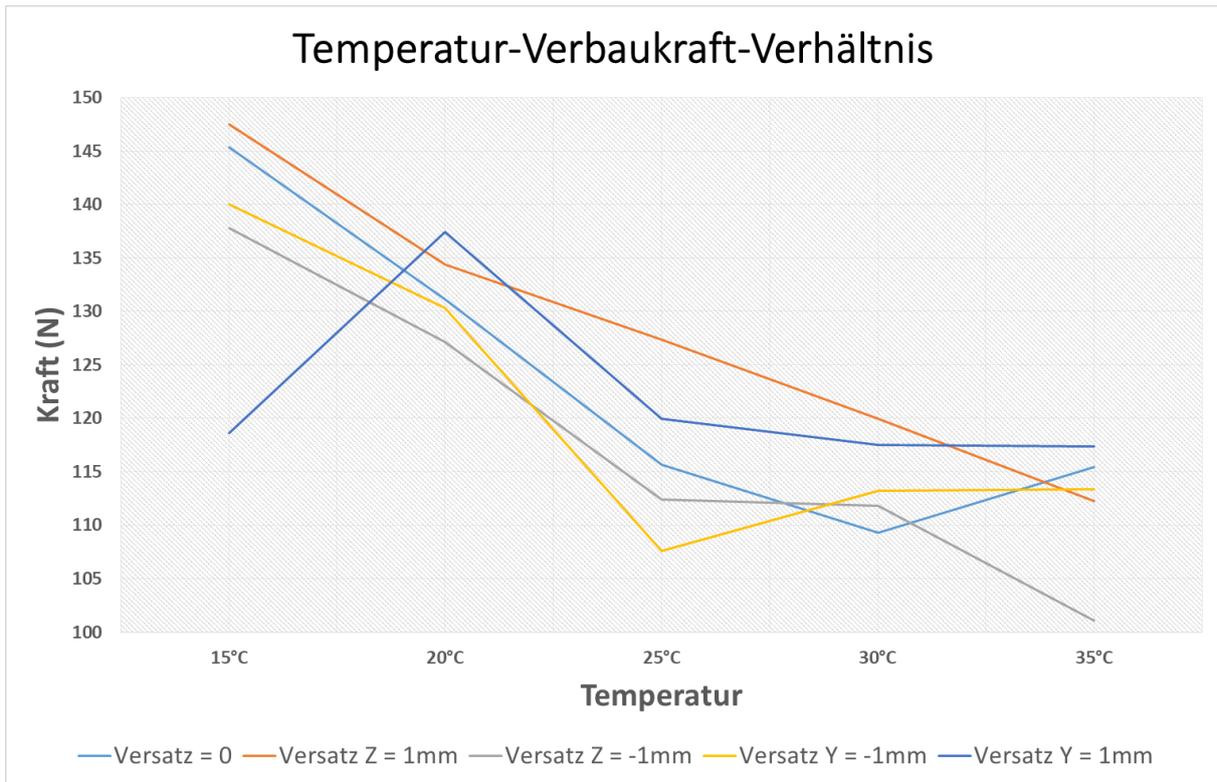
Für IO am Roboter und Sockel

Sensor-Position	Max St. 1 (~5s)	Max. St. 2 (~13s)	Max. St. 3 (~20s)	Max. St. 4 (~27s)	Max. St. 5 (~34s)	Minimal	Maximal
X	-	-	-	-	-	-	-
Y	0,305mm	0,414mm	0,419mm	-	-	0,305mm	0,419mm
Z	0,141mm	0,209mm	0,304mm	-	-	0,141mm	0,304mm
Sockel	0,724µm	1,518µm	1,396µm	-	-	0,724µm	1,518µm
Band	1,098µm	0,771µm	0,938µm	-	-	0,771µm	1,098µm
X	-	-	-	-	-	-	-
Y	0,256mm	0,256mm	0,302mm	0,163mm	-	0,163mm	0,302mm
Z	0,144mm	0,132mm	0,159mm	0,185mm	-	0,132mm	0,185mm
Sockel	0,871µm	0,918µm	1,060µm	0,623µm	-	0,623µm	1,060µm
Band	0,894µm	0,833µm	0,722µm	0,794µm	-	0,722µm	0,894µm
X	-	-	-	-	-	-	-
Y	0,843mm	0,309mm	0,389mm	0,560mm	0,537mm	0,309mm	0,843mm
Z	0,168mm	0,262mm	0,132mm	0,102mm	0,430mm	0,102mm	0,430mm
Sockel	0,725µm	0,732µm	1,060µm	0,915µm	0,968µm	0,725µm	1,060µm
Band	0,822µm	0,674µm	0,671µm	0,971µm	0,622µm	0,622µm	0,971µm
X						-	-
Y						0,163mm	0,843mm
Z						0,102mm	0,430mm
Sockel						0,623µm	1,518µm
Band						0,622µm	1,098µm

Für NIO am Roboter und Sockel

Sensor-Position	Max. St. 1 (.5s)	Max. St. 2 (~13s)	Max. St. 3 (~20s)	Max. St. 4 (~27s)	Max. St. 5 (~34s)	Minimal	Maximal
X	-	-	-	-	-	-	-
Y	0,482mm	0,311mm	0,477mm	-	-	0,311mm	0,482mm
Z	0,142mm	0,193mm	0,234mm	-	-	0,142mm	0,234mm
Sockel	1,024µm	1,013µm	1,174µm	-	-	1,013µm	1,174µm
Band	0,872µm	0,656µm	0,659µm	-	-	0,656µm	0,872µm
X	-	-	-	-	-	-	-
Y	0,397mm	0,292mm	0,266mm	0,184mm	-	0,184mm	0,397mm
Z	0,127mm	0,160mm	0,168mm	0,205mm	-	0,127mm	0,205mm
Sockel	0,860µm	0,664µm	1,158µm	1,123µm	-	0,664µm	1,158µm
Band	0,852µm	0,582µm	0,565µm	0,717µm	-	0,565µm	0,852µm
X	-	-	-	-	-	-	-
Y	0,213mm	0,306mm	0,246mm	0,300mm	0,318mm	0,213mm	0,318mm
Z	0,186mm	0,192mm	0,131mm	0,201mm	0,195mm	0,186mm	0,201mm
Sockel	1,027µm	0,667µm	0,945µm	0,822µm	0,602µm	0,602µm	1,027µm
Band	0,705µm	0,516µm	0,808µm	0,589µm	0,747µm	0,516µm	0,808µm
X						-	-
Y						0,184mm	0,482mm
Z						0,127mm	0,234mm
Sockel						0,602µm	1,174µm
Band						0,516µm	0,872µm

### C: Untersuchungen des Temperatur-Verbaukraftverhältnisses



## D: Vergleich Vorhersageergebnisse unterschiedlicher Datenvorska- lierungen

	Spezifitaet	Sensitivitaet	Relevanz	Segreganz	LRP	LRN	Korrektklassifikationsrate	F-Mass	F2-Mass
MLP (CNN+FCNN) Sensor- & Bilddaten [0,1]	0.77	0.78	0.74	0.81	3.45	0.28	0.78	0.76	0.77
MLP (CNN+FCNN) Sensor- & Bilddaten [my=0,sigma=1]	0.77	0.78	0.74	0.81	3.43	0.29	0.78	0.76	0.77

MLP (CNN+FCNN) mit Sensor- und Bilddaten [0,1]

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	213	74	287
Vorhersage I.O.	60	253	313
Summe	273	327	600

MLP (CNN+FCNN) mit Sensor- und Bilddaten [my=0,sigma=1]

	N.I.O	I.O.	Summe
Vorhersage N.I.O.	212	74	286
Vorhersage I.O.	61	253	314
Summe	273	327	600