

**Band
417**

Verlagsschriftenreihe des Heinz Nixdorf Instituts
Prof. Dr.-Ing. Ansgar Trächtler (Hrsg.)
Regelungstechnik und Mechatronik

Manuel Gräler

Entwicklung adaptiver Einrichtassistenzsysteme für Produktionsprozesse

Manuel Gräler, M.Sc.

Entwicklung adaptiver Einrichtassistentensysteme für Produktionsprozesse

Design of Adaptive Setup-Assistants for Production Processes

Bibliografische Information Der Deutschen Bibliothek

Die Deutsche Bibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.ddb.de> abrufbar

Band 417 der Verlagsschriftenreihe des Heinz Nixdorf Instituts

© Heinz Nixdorf Institut, Universität Paderborn – Paderborn – 2024

ISSN (Print): 2195-5239
ISSN (Online): 2365-4422
ISBN: 978-3-947647-36-1

Das Werk einschließlich seiner Teile ist urheberrechtlich geschützt. Jede Verwertung außerhalb der engen Grenzen des Urheberrechtsgesetzes ist ohne Zustimmung der Herausgeber und des Verfassers unzulässig und strafbar. Das gilt insbesondere für Vervielfältigung, Übersetzungen, Mikroverfilmungen, sowie die Einspeicherung und Verarbeitung in elektronischen Systemen.

Als elektronische Version frei verfügbar über die Digitalen Sammlungen der Universitätsbibliothek Paderborn.

Satz und Gestaltung: Manuel Gräler, M.Sc.

Entwicklung adaptiver Einrichtassistenzsysteme für Produktionsprozesse

zur Erlangung des akademischen Grades eines
DOKTORS DER INGENIEURWISSENSCHAFTEN (Dr.-Ing.)
der Fakultät Maschinenbau
der Universität Paderborn

genehmigte
DISSERTATION

von
Manuel Gräler, M.Sc.
aus Versmold

Tag des Kolloquiums: 28. August 2023

Referent: Prof. Dr.-Ing. habil. Ansgar Trächtler

Korreferent: Prof. Dr.-Ing. Werner Homberg

Vorwort

All life is an experiment.
The more experiments you make the better.

Ralph Waldo Emerson

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter und Gruppenleiter am Fraunhofer IEM in Paderborn. Bedanken möchte ich mich sehr herzlich bei Prof. Dr.-Ing. habil. Ansgar Trächtler für die Betreuung der Dissertation, die stets konstruktiven und bereichernden Diskussionen und die vertrauensvolle Zusammenarbeit. Prof. Dr.-Ing. Werner Homberg danke ich für die Übernahme des Korreferats, für wertvolles Feedback und auch für die produktiven Projektkooperationen während meiner Zeit am Fraunhofer IEM. Ich bedanke mich herzlich bei Prof. Dr.-Ing. Balázs Magyar und Prof. Dr.-Ing. Elmar Moritzer für das Mitwirken in der Promotionskommission.

Ein besonderer Dank gilt meiner Frau Janine, die maßgeblich zum Gelingen und zum Abschluss der Dissertation beigetragen hat. Sei es durch Motivationsschübe, Korrekturen oder durch das Verschaffen von Zeiträumen zur Ausarbeitung der Dissertation. Mein Dank gilt natürlich auch meinen Eltern Petra und Jürgen, die mich stets unterstützt haben.

Bedanken möchte ich mich auch bei dem Team des Projekts Self-X-Pro², welches durch die tolle Zusammenarbeit natürlich auch einen wichtigen und wesentlichen Beitrag zum Gelingen dieser Arbeit beigetragen hat. So möchte ich Lars Brinkmann (Weidmüller GmbH & Co KG) und Robert Springer (Universität Paderborn) für die außerordentlich produktive und kollegiale Zusammenarbeit danken. Zusätzlich möchte ich Dr.-Ing. Jan Stefan Michels (Weidmüller GmbH & Co KG) für die sehr gute Projektleitung und das uns entgegen gebrachte Vertrauen während des Projekts danken. Ein herzlicher Dank geht auch an meinen damaligen (und heutigen) Teamleiter Dr.-Ing. Martin Krüger, der mir das Projekt anvertraut und mich zum Verfassen einer Dissertation motiviert hat.

Ein herzlicher Dank gebührt meinen ehemaligen Kollegen vom Fraunhofer IEM. Danke Alina Hellweg, Dr.-Ing. Christopher Lankeit, Jan Michael und Jens Holtkötter für die interessanten Diskussionen und vor allem die schöne Zeit am IEM. Ein besonderer Dank geht an Simon Drüke, der mir zusätzlich mit strengem Blick zu dieser Arbeit ausführliches und sehr hilfreiches Feedback gegeben hat. Auch Maximilian Bause möchte ich herzlich für seine Unterstützung als studentische Hilfskraft während meiner Zeit am IEM danken.

Zusammenfassung

Die vorliegende Arbeit ist im Bereich der Produktionstechnik situiert, welche sich in einem stetigen Wandel befindet. Ein Trend in der Produktion sind individualisierte Produkte und damit eine höhere Variantenvielfalt, die idealerweise durch effiziente Produktionsprozesse hergestellt werden. Effizienz bedeutet in diesem Fall, dass die Produkte kostengünstig und bedarfsgerecht hergestellt werden. Der Trend geht hierbei auch in der Massenproduktion zu einer flexiblen Produktion, um das gebundene Kapital zu reduzieren und zeitnah auf Kundenwünsche reagieren zu können. Dies führt zu einem häufigeren Umrüsten der Werkzeuge in den Maschinen und somit zu einem immer häufigeren Einrichten der Prozesse. In dieser Arbeit wird eine Systematik für ein adaptives Einrichtassistenzsystem (EAS) entwickelt, welches den Maschinenbediener beim Einrichten mithilfe eines definierten Vorgehens durch den Prozess leitet. Der Bediener wird dabei unterstützt die momentane Produktqualität zu bewerten und bekommt einen quantitativen Vorschlag zur Variation der Justagemöglichkeiten. So kann der Einrichtprozess zielgerichteter und fehlerfreier durchgeführt werden. Ermöglicht wird dies durch die Abbildung des notwendigen Expertenwissens in datengetriebenen Modellen. Mithilfe des so abgebildeten Expertenwissens werden optimierte Einstellungen berechnet und am Werkzeug eingestellt. Es ist nicht davon auszugehen, dass das virtualisierte Expertenwissen die Realität allumfassend abbilden und alle akuten Umwelteinflüsse messtechnisch ermittelt werden können. Etwaige Abweichungen der Produktqualität werden direkt in der entwickelten Optimierung und bei Bedarf mithilfe der vorgeschlagenen Kompensationsstrategie eliminiert. Die Systematik wird anhand eines Folgeverbundprozesses validiert. Nach der Analyse des Prozesses werden die wesentlichen Komponenten für das System entwickelt und mithilfe von Versuchen und Simulationen die Funktionsfähigkeit erfolgreich nachgewiesen.

Abstract

This thesis is situated in the field of production technology, which is in a constant state of change due to its progressive development. A trend in production are individualized products and thus a higher number of variants, which are ideally produced by efficient production processes. In this case, efficiency means that the products are manufactured at low cost and in line with demand. This trend, flexible manufacturing, is also valid for mass production, in order to reduce tied up capital and still be able to react promptly to customer demands. This leads to more frequent retooling in the machines and thus also to an increasingly frequent setting up of the processes. In this thesis, a systematic for an adaptive set-up assistant is developed, which guides the machine operator through the process during setup. The machine operator is supported in evaluating the current product quality and receives a quantitative proposal for the variation of the adjustment possibilities. Thus, the set-up process can be carried out in a more targeted and error-free manner. This is made possible by mapping the necessary expert knowledge in data-driven models. The expert knowledge is used to calculate optimized settings and adjust them on the tool. It cannot be assumed that virtualized expert knowledge will comprehensively map reality and that all acute environmental influences can be measured. Any deviations in product quality are directly eliminated in the developed optimization and, if necessary, with a proposed compensation strategy. The system is validated with a progressive tool. After analyzing the process, the essential components for the system are developed and their functionality is successfully demonstrated by means of tests and simulations.

Vorveröffentlichungen

- [GSH⁺18] GRÄLER, M.; SPRINGER, R.; HENKE, C.; TRÄCHTLER, A.; HOMBERG, W.: Assisted setup of forming processes: compensation of initial stochastic disturbances. *Procedia Manufacturing* 25 (2018), S. 358–364
- [GWHT19] GRÄLER, M.; WALLOW, A.; HENKE, C.; TRÄCHTLER, A.: Assisted setup of forming processes: architecture for the integration of non-adjustable disturbances. *Procedia CIRP* 81 (2019), S. 1348–1353
- [PGH⁺16] PEITZ, S.; GRÄLER, M.; HENKE, C.; MOLO, M. H.-v.; DELLNITZ, M.; TRÄCHTLER, A.: Multiobjective Model Predictive Control of an Industrial Laundry. *Procedia Technology* 26 (2016), S. 483–490
- [SGH⁺18] SPRINGER, R.; GRÄLER, M.; HOMBERG, W.; HENKE, C.; TRÄCHTLER, A.: Model-based setup assistant for progressive tools. *AIP Conference Proceedings* (2018)
- [Trä18] TRÄCHTLER, A., Hrsg.: *Ressourceneffiziente Selbstoptimierende Wäscherei: Ergebnisse des ReSerW-Projekts*. Intelligente Technische Systeme - Lösungen aus dem Spitzencluster it's OWL. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018.

Entwicklung adaptiver Einrichtungssysteme für Produktionsprozesse

Inhaltsverzeichnis

1 Einleitung	1
2 Stand der Technik	7
2.1 Kategorisierung von Produktionsverfahren	7
2.2 Das Einrichten von Produktionsprozessen	14
2.3 Assistenzsysteme in der Produktion	18
2.3.1 Klassifikation der Assistenzsysteme	18
2.3.2 Assistenzsysteme in der Produktion	25
2.4 Datengetriebene Modellbildung	28
2.4.1 Response-Surface Methode	28
2.4.2 Machine Learning Verfahren	38
2.5 Zusammenfassung und Fazit	48
3 Entwicklung einer Systematik für Einrichtungssysteme	53
3.1 Klassifikationssystematik	54
3.2 Rahmenbedingungen und Anforderungen	59
3.3 Entwicklung der Referenzarchitektur	66
3.3.1 Stellgrößenmodelle	68
3.3.2 Störgrößenmodelle	69
3.3.3 Berechnung der Startwerte	70
3.3.4 Kompensation der Störungen	71
3.4 Vorgehensweise	74
3.5 Bewertung der Anforderungserfüllung	76
4 Validierung der Systematik für Einrichtungssysteme	81
4.1 Analyse des Folgeverbundwerkzeugs	81
4.1.1 Voruntersuchung Stellgrößenmodell	83
4.1.2 Voruntersuchung Störgrößenmodell	90
4.1.3 Zusammenfassung der Analyse	92
4.2 Anwendung der Einrichtsystematik	93
4.2.1 Stellgrößenmodell	94
4.2.2 Validierung der Einrichtsystematik mit dem Stellgrößenmodell	99
4.2.3 Störgrößenmodell	104
4.2.4 Einrichtsystematik mit Störgrößenmodellen	112

4.3 Bewertung der Ergebnisse	115
5 Zusammenfassung und Ausblick	121
5.1 Zusammenfassung	121
5.2 Ausblick	126
Literatur	129

Anhang

1 Einleitung

Für den Wohlstand des Industriestandorts Deutschland ist die Produktion ein wesentlicher wirtschaftlicher Faktor. So trägt das produzierende Gewerbe ungefähr ein Viertel zum deutschen Bruttoinlandsprodukt des Jahres 2019 bei [Sta20]. In den letzten Jahren wurden von der Bundesregierung viele Aktivitäten initiiert, um diesen wichtigen Beitrag für den Standort Deutschland zu sichern und die Wettbewerbsfähigkeit zu erhalten. Eine dieser Aktivitäten ist die Industrie 4.0, eine High-Tech Strategie, die die Digitalisierung der Produktion fokussiert. Trotz aller Digitalisierungsaktivitäten ist der Mensch auch in absehbarer Zeit nicht aus der Produktion wegzudenken. Es gilt daher auch weiterhin, den Menschen hier bestmöglich zu unterstützen – dies geschieht unter anderem mithilfe so genannter Assistenzsysteme. Diese Arbeit trägt einen Teil zur Standortsicherung bei, da mit dem hier entwickelten Ansatz der Anteil der wertschöpfenden Zeit an der Maschinenzeit und somit die Wettbewerbsfähigkeit erhöht werden kann. Das erste Kapitel erläutert die Motivation der vorliegenden Dissertation und extrahiert aus dieser eine Zielsetzung. Basierend auf den beiden Komponenten wird dann die Vorgehensweise dieser Arbeit abgeleitet und ein Überblick über die Gliederung gegeben.

Motivation

Vollautomatisierte und geregelte Prozesse passen ihre Einstellungen an die aktuelle Situation an, um definierte Produkteigenschaften zu gewährleisten. Allerdings sind diese auch in der Metallverarbeitung zur Zeit nur in seltenen Fällen üblich. So müssen Prozessschritte manuell bestückt, komplexe Montageschritte durch Fachpersonen durchgeführt oder die Produktqualität stichprobenartig manuell erfasst werden. Es existieren vielfältige Prozesse mit unterschiedlichen Produktionsverfahren, die – einmal richtig eingestellt – robust die gewünschten Produkte herstellen. Robust heißt, dass für eine endliche Zeit die gewünschte Qualität erreicht wird. Beispiele für diese Prozesse sind

- Spritzgussanlagen,
- Pressen,
- Radial-Stanzbiegeautomaten,
- Federwindemaschinen oder auch
- Folgeverbundprozesse.

Den Prozessen ist ebenfalls gemein, dass eine Maschine mit produktspezifischen Werkzeugen ausgestattet wird. Die Maschine stellt dabei die Rahmenbedingungen zur Verfügung und die Werkzeuge enthalten über ihre Form, Abfolge oder Ansteuerung implizit einen Teil des Prozesswissens. Dieses dient der Produktion des spezifischen Produkts mit den notwendigen Eigenschaften. Am Beispiel eines Folgeverbundwerkzeugs bedeutet dies, dass eine Schnellläuferpresse eine definierte Umgebung für das Werkzeug liefert. Dieses Werkzeug wurde so konstruiert, dass es das Halbzeug in einer definierten Sequenz zu dem gewünschten Produkt verarbeitet. Während der Produktion der Bauteile werden die drei gegenläufigen Ziele Qualität, Zeit und Kosten (siehe Abbildung 1-1) verfolgt, für




Bild 1-1: Gegenläufige Ziele in der Produktion nach [KS14, S. 4]

die ein individueller Kompromiss gefunden werden muss. In den Unternehmen werden meist mehrere Produkte auf einer Anlage gefertigt, sodass es mehr Werkzeuge als Maschinen gibt. Resultierend müssen die Prozesse für die Herstellung der einzelnen Produkte umgerüstet werden. Das stetige Umrüsten stellt ein zu vernachlässigendes zeitliches und wirtschaftliches Problem dar, solange die eigentliche Produktionszeit die Rüstzeit deutlich übersteigt.

Das Rüsten ist der Prozess, der die benötigte Qualität für das nächste zu fertigende Produkt sicherstellt: neben dem Einbau der Werkzeuge in die Maschinen müssen die Mitarbeiter beim Rüsten ggf. Peripherie in Betrieb nehmen (z.B. Kamerasysteme zur Qualitätssicherung), das Material zuführen, die Werkzeuge einstellen und den Produktionsprozess einfahren. Dies ist ein aufwändiger Prozess und je nach Prozesskomplexität zeitintensiv. Das Einrichten selbst ist eine sehr anspruchsvolle Aufgabe, deren Ergebnisqualität bei den zur Zeit üblichen Anlagen bedienerabhängig ist. Beim Einrichten greift der Bediener auf sein Erfahrungswissen und in vielen Fällen auch auf Dokumentationen zurück, um den Prozess zu justieren und die Produktqualität einzustellen. Die Justage kann über verschiedene Eingriffsmöglichkeiten des Prozesses realisiert werden. Neben Software-Parametern können manuelle Eingriffsmöglichkeiten wie Stellschrauben oder auch Aktoren eingesetzt werden. Mithilfe dieser Justagemöglichkeiten wird der Prozess feingranular verändert und so die Produktqualität beeinflusst. Während dieser Aufgabe muss der Produktionsprozess (siehe Abbildung 1-2) ganzheitlich betrachtet werden: die Justagemög-




Bild 1-2: Systembetrachtung eines generalisierten Produktionsprozesses

lichkeiten werden solange nach Einschätzung des Experten variiert, bis die notwendige Produktqualität erreicht wird und die Auswirkungen der Umwelteinflüsse hinreichend kompensiert sind. Je nach Anzahl und Vielfalt der Justagemöglichkeiten und Qualitätskenngrößen, sowie der Zusammenhänge (zum Beispiel nichtlineares Verhalten oder auch

Wechselwirkungen) ist dies eine für den Menschen schwierige und zeitintensiv zu lösende Herausforderung.

Der demographische Wandel führt in absehbarer Zeit zu einem großen Verlust von Expertenwissen in den Unternehmen. Dies trifft nicht nur die Entwicklungsabteilungen der deutschen High-Tech Industrie, sondern auch deren Produktion. Häufig ist das Wissen über die Produktionsprozesse in den Köpfen der erfahrenen Mitarbeiter konserviert, die in den nächsten Jahren in den Ruhestand gehen werden. Verschärfend kommt hinzu, dass der Arbeitsmarkt für qualifizierten Nachwuchs hart umkämpft ist: häufig können daher die ausscheidenden Mitarbeiter nicht adäquat ersetzt werden. Fehlendes Erfahrungswissen führt zu zeit- und damit kostenintensiven Prozessen. Dies ist einer der Gründe für das Ziel vieler Unternehmen die Produktionsprozesse weitestgehend zu automatisieren. So werden sie unabhängig von dem individuellen Erfahrungswissen des einzelnen Mitarbeiters und die Zeit wertschöpfender Tätigkeiten wird maximiert. Für Produkte mit einer hohen Stückzahl ist die Automatisierung in einem wirtschaftlichen Rahmen durchführbar, wird aber durch eine wachsende Vielfalt der Produkte erschwert. Dies ist darin begründet, dass die Produktionsprozesse flexibel anpassbar sein müssen, um den neuen Anforderungen eines weiteren Produkts zu genügen.

Ein zusätzlicher langanhaltender Trend in der Produktion sind individualisierte Produkte und damit eine höhere Variantenvielfalt, die durch effiziente Produktionsprozesse hergestellt werden. Effizienz bedeutet in diesem Fall, dass die Produkte kostengünstig und bedarfsgerecht hergestellt werden. Dieser Trend wurde bereits in den Anfängen des Computer Integrated Manufacturings (CIM) um 1990 identifiziert [Gör92, S. 2 f.]. Der Trend geht hierbei auch in der Massenproduktion zu einer flexiblen Produktion, um das gebundene Kapital zu reduzieren und trotzdem zeitnah auf Kundenwünsche zu reagieren. Dies führt zu einem häufigeren Ab- und Aufbau der Werkzeuge in den Maschinen und somit ebenfalls zu einem immer häufigeren Einrichten der Prozesse. Somit sinkt der Anteil der wertschöpfenden Tätigkeit an der Maschinenzeit und die Effizienz der Produktion sinkt. Lösungsmöglichkeiten sind somit die bereits genannte höhere Automatisierung oder eine bessere Unterstützung des Bedieners. Erstere geht insbesondere für Bestandsanlagen mit einem erhöhten Investitions- und Entwicklungsvolumen einher, da die vielfältigen Anwendungen Berücksichtigung finden müssen. Letzteres reduziert die noch notwendigen Arbeiten auf ein Minimum, da der Maschinenbediener genau weiß, was zu tun ist.

Um solch komplexe Herausforderungen wie die des Einrichtens zu lösen, wurden in den letzten Jahren, auch im Rahmen der „Industrie 4.0“, vielfältige Assistenzsysteme für Produktionssysteme erforscht und entwickelt. Ausprägungen von diesen Systemen unterstützen die Mitarbeiter qualitativ bei der Bedienung eines Prozesses, weisen auf Anomalien oder auch auf Wartungsaufgaben hin. Viele Assistenzsysteme zeichnet aus, dass sie den Bediener qualitativ bei seinen Aufgaben unterstützen. Das heißt, es wird dabei unterstützt was getan und nicht in welchem genauen Umfang eine Aufgabe erledigt werden muss. Zusätzlich finden sich nur wenige Systeme, die eine Unterstützung bei dem Einrichten eines Prozesses bieten und wenn, sind sie speziell auf einen Prozess konfektioniert.

Zielsetzung und Vorgehensweise

Aus den eben aufgeführten Beweggründen wird in dieser Arbeit eine Systematik für ein adaptives EAS entwickelt, welches den Maschinenbediener beim Einrichten durch ein

Vorgehen unterstützt. Diese wird an einem Beispielprozess validiert. Mit der Systematik bekommt der Bediener Hilfestellung die momentane Produktqualität zu bewerten und erhält einen quantitativen Vorschlag zur Variation der Justagemöglichkeiten für eine optimale Produktqualität. So kann der Einrichtprozess zielgerichteter und fehlerfreier durchgeführt werden. Der Anspruch der Arbeit ist hierbei einen allgemeingültigen Ansatz zu entwickeln, der auf verschiedene einzurichtende Produktionsprozesse übertragen werden kann: Teil des Systematik ist eine modulare Architektur, die beim Aufbau und dem Konservieren des Expertenwissens über die Produktionsprozesse unterstützt. Diese Systematik ist maßgeblich für die Übertragung des Konzepts auf unterschiedliche Produktionsprozesse: Aufgrund der oben genannten Ausstattungsdiversität der Produktionsprozesse hinsichtlich Sensorik und Aktorik wird stets ein prozessindividuelles Konzept benötigt. So werden einige Produktionsprozesse rein mechanisch eingestellt, andere hingegen haben eine gesteuerte, zum Teil auch geregelte Aktuatorik. Je nach Ausstattung kann der Bediener unterschiedlich mit konserviertem Expertenwissen unterstützt werden, sodass dies in dem Konzept Berücksichtigung finden muss.

Das EAS soll die Möglichkeit bieten Expertenwissen zielgerichtet zu erfassen und abzubilden, um einen möglichst objektiven und quantitativen Blick auf die Prozesse zu erlangen. Das Wissen muss effizient, automatisiert und werkzeugindividuell erstellt werden können, da die Produktionsprozesse auch innerhalb einer Prozessgruppe (beispielhaft unterschiedliche Folgeverbundprozesse) sich signifikant voneinander unterscheiden und in hoher Anzahl vorkommen. Weiterhin sollten sie unabhängig vom Erfahrungswissen des einzelnen Bedieners erstellt werden, um die Objektivität zu erhöhen. Mithilfe des abgebildeten Expertenwissens werden dann optimierte Einstellungen berechnet und am Werkzeug eingestellt. Es ist prinzipbedingt nicht davon auszugehen, dass das virtualisierte Expertenwissen die Realität allumfassend abbildet und alle akuten Umwelteinflüsse messtechnisch ermittelt werden können. Etwaige Abweichungen der Produktqualität werden direkt in der Optimierung oder mithilfe einer Kompensationsstrategie eliminiert. Idealerweise unterstützt das EAS von Beginn an den Maschinenbediener bei seiner Arbeit und liefert innerhalb von kurzer Zeit funktionsfähige Ergebnisse. Eine lange Lernzeit für das System soll vermieden werden.

Nichtsdestotrotz sollte das EAS die Möglichkeit vorsehen, über die Nutzungszeit weiteres Erfahrungswissen aufzubauen. Hierbei wäre hilfreich, die messbaren Störungen ebenfalls in den Berechnungen zu berücksichtigen. Perspektivisch kann das so aufgebaute Wissen zurück in die Werkzeugentwicklung gespiegelt werden, um diese durch tiefgehendes Erfahrungswissen zu unterstützen und zu optimieren.

Zum Erreichen des im Vorfeld erläuterten Ziels, die Entwicklung einer Systematik für ein adaptives EAS, ist im Wesentlichen eine Betrachtung zweier interdisziplinärer Bereiche notwendig. So spielt die Produktionstechnik eine große Rolle, da sich das System später in die Produktion und den zugehörigen Entwicklungsprozessen einordnen muss. Weiterhin stützt sich das System auf potenziell im Entwicklungs- und Produktionsprozess anfallende Daten, daher ist der andere signifikante Bereich die datengetriebene Modellierung von technischen Systemen. Es resultiert die in Abbildung 1-3 dargestellte Gliederung.

Zunächst werden im Stand der Technik (siehe Abbildung 1-3, Kapitel 2) im Abschnitt 2.1 Produktionsprozesse allgemein charakterisiert und kategorisiert. Dies dient zur Einordnung und Definition der in dieser Arbeit betrachteten Produktionsprozesse und deren Automatisierungsgrad. Darauf aufbauend wird in Abschnitt 2.2 die Aufgabe des Einrichtens




Bild 1-3: Gliederung der Arbeit

der Produktionsprozesse näher erläutert und in den Rüstprozess eingeordnet. Abschließend werden in Abschnitt 2.3 bereits vorhandene Klassifikationssystematiken für Produktionsprozesse dargelegt und systematisiert. Dies dient zur möglichen Einordnung der hier entwickelten Systematik. Darauf aufbauend wird im Abschnitt 2.4 die datengetriebene Modellbildung in der Produktion betrachtet. Es wird analysiert, welche Methoden in welchen Bereichen der Produktion genutzt werden und die Grundlagen erörtert. Beispiele sind die Response-Surface Methode, aber auch maschinelle Lernverfahren. In dem abschließenden Fazit des Kapitels (siehe Abschnitt 2.5) wird die Zielsetzung dieser Arbeit aus dem vorgestellten Stand der Technik abgeleitet und der Mehrwert einer Systematik für EAS aufgezeigt.

Im Kapitel 3 wird die Systematik für das EAS entwickelt und erläutert. Im Stand der Technik zeigt sich, dass eine hinreichend gute Charakterisierung des EAS mit den vorhandenen Klassifikationssystematiken nicht möglich wird. Daher wird zunächst eine eigene Charakterisierung solcher Assistenzsysteme in der Produktion entwickelt. Zusätzlich werden die Rahmenbedingungen und die Anforderungen in Abschnitt 3.2 herausgearbeitet, sodass abschließend das EAS vollständig charakterisiert werden kann. So wird im nächsten Abschnitt 3.3 eine Referenzarchitektur als wesentlicher Teil der Systematik entwickelt. Sie ermöglicht die Berechnung idealer Prozessparameter mithilfe von Stell- und Störgrößenmodellen. In der Architektur wird eine überlagerte numerische Optimierung vorgesehen, um nicht messbare Störungen zu kompensieren. Die anschließende Erörterung der Vorgehensweise für die Anwendung der Systematik schließt das Kapitel ab und bildet die Gliederung für das nächste Kapitel.

Im Kapitel 4 wird die entwickelte Systematik beispielhaft angewendet und die notwendigen Entwicklungsschritte aufgezeigt. Das Validierungsbeispiel ist ein Folgeverbundwerkzeug (FVWZ), welches in der elektrischen Verbindungsindustrie eingesetzt wird. Zunächst wird dieses Werkzeug in Abschnitt 4.1 vorgestellt und analysiert, um einen Überblick über das System zu erlangen. Neben der Analyse der Stellgrößen werden ebenfalls die zu betrachtenden Qualitätsmerkmale definiert. Weiter wird die 5M-Methode genutzt, um signifikante Störeinflüsse für diesen Prozess zu ermitteln. Die Auswirkungen der identifizierten Störeinflüsse auf die Qualitätsmerkmale der Produkte gilt es dann mithilfe der Eingriffsmöglichkeiten des Folgeverbundprozesses (FVP) zu kompensieren. Hierzu wird die im letzten Kapitel entwickelte Systematik inklusive der Referenzarchitektur angewendet, sodass ein adaptives Einrichtungsassistenzsystem entsteht. Die Systematik wird anhand von Versuchen und Simulationen validiert und die Ergebnisse bewertet. Die Arbeit endet im Kapitel 5 mit einer Zusammenfassung und einem Ausblick. Es wird perspektivisch erläutert, in welche Richtungen die vorgeschlagene Systematik weiter ausgebaut und genutzt werden kann. Hierbei wird aufgezeigt, dass gerade in der Produktion noch vielfältige Herausforderungen zu bewältigen sind, bis eine nahezu autonome Produktion ermöglicht wird.

2 Stand der Technik

In diesem Kapitel wird der aktuelle Stand der Technik und Wissenschaft für die vorliegende Arbeit erörtert. Das Ziel der Arbeit ist die Entwicklung einer allgemein anwendbaren Systematik für Einrichtassistenzsysteme, um die Maschinenbediener beim Einrichten vorhandener Produktionsprozesse zu unterstützen. Zunächst werden die Produktionsprozesse kategorisiert, um einen Überblick über die hohe Vielzahl der existierenden Prozesse zu geben. Anschließend wird die verschieden ausgeprägte Automatisierung dieser Prozesse näher beleuchtet. Folglich können die unterschiedlichen Phasen der Produktionsprozesse in der Produktion erörtert werden. Das Einrichten als Teil des Rüstprozesses und wichtiger Bestandteil dieser Arbeit wird anschließend näher dargestellt. Basierend auf diesen Erkenntnissen werden dann in der Industrie und Wissenschaft bekannte Assistenzsysteme für das Einrichten beleuchtet und systematisiert. Den Abschluss für dieses Kapitel bildet die datengetriebene Modellbildung im Produktionsumfeld, die eine methodische Grundlage für die Systematik des EAS darstellt.

2.1 Kategorisierung von Produktionsverfahren

Nach DIN 8580 [DIN03] können Produktionsverfahren in sechs hierarchisch gleichwertige Gruppen unterteilt werden (siehe Abbildung 2-1). Eine Gruppe ist die der urformenden Verfahren. Diese Verfahren schaffen ein neues Produkt aus einem formlosen Stoff. Beispiele hierfür sind das Gießen, Spritzgießen oder auch das Sintern. Eine weitere Gruppe ist das Umformen, welches sich mit der plastischen Änderung eines geformten Stoffes beschäftigt. Exemplarisch für diese Gruppe sind das Biegeumformen, Walzen oder auch Tiefziehen. Im Gegensatz zum Umformen, wird bei der nächsten Gruppe, den trennenden Verfahren Material vom ursprünglich geformten Stoff abgetragen und so die Form geändert. Bekannte Beispiele sind hier das Bohren, Fräsen oder auch Stanzen. In der Gruppe des Fügens werden unterschiedliche Werkstoffe miteinander verbunden. Beispiele hierfür sind das Schweißen, Kleben oder auch Nieten.

Eine weitere Kategorie sind die beschichtenden Verfahren, welche gemein haben, dass eine haftende Schicht aus formlosem Stoff auf ein Werkstück aufgebracht wird. Bei den Verfahren wird maßgeblich der Zustand des formlosen Stoffes zur Charakterisierung genutzt.



Bild 2-1: Unterteilung der Produktionsverfahren, nach DIN 8580

So variieren die Beispiele vom Lackieren (flüssiger Zustand), zum Spachteln (plastischer Zustand) oder auch dem Bedampfen (aus dem gasförmigen Zustand). Die letzte Kategorie beinhaltet die Prozesse, die die Stoffeigenschaften des Werkstücks ändern. Beispiele sind hier das Kaltverfestigen durch Umformen, thermische Behandlungen oder auch das Sintern.

Es ist offensichtlich, dass eine Vielzahl differierender Verfahren existiert, die individuelle Eigenschaften und damit Vor- sowie Nachteile mit sich bringen. Sie eignen sich so in verschiedener Zusammensetzung für unterschiedliche Produkte. Um mithilfe der Verfahren Produkte erfolgreich herzustellen, ist tiefgehendes Wissen zur Entwicklung eines geeigneten Produktionsprozesses erforderlich. Erfolgreich in diesem Kontext heißt, dass die Produkte mit benötigter Qualität, in möglichst kurzer Zeit mit geringen Kosten fertiggestellt werden, wie in Abbildung 1-1 dargestellt. Das hierfür notwendige Prozesswissen kann zum einen der Hersteller der Produktionsanlagen durch die Informationsverarbeitung oder auch Dokumentationen mitliefern. Zum anderen kann das Wissen ebenfalls von den Anwendern der Produktionsprozesse aufgebaut werden und so einen wesentlichen Teil der Unternehmensexpertise ausmachen. Die notwendige Expertise ist dabei prozessindividuell und kann beispielsweise abhängig sein von der Materialauswahl, den einzusetzenden Werkzeugen, Prozessparametern, Maschineneinstellungen oder auch notwendigen Vorprozessen.

Automatisierungsgrade von Produktionsprozessen

Wie beschrieben, kann das notwendige Vorwissen ebenfalls in der Informationsverarbeitung des Produktionsprozesses vom Hersteller abgelegt sein. Eine Anlage mit einem höheren Automatisierungsgrad beinhaltet dementsprechend mehr Prozesswissen, als eine geringfügig automatisierte Anlage, die erst durch den Anwender befähigt wird die Produkte zu fertigen. Neben der Unterteilung nach Produktionsverfahren können Produktionsprozesse nach ihrem Automatisierungsgrad unterteilt werden. Hierbei wurden in [DBP⁺18; GHKK18] sechs Automatisierungsgrade identifiziert (siehe Abbildung 2-2), die an die fünf Stufen des autonomen Fahrens (siehe zum Beispiel [BU20, S. 10]) angelehnt sind.

Die Ausgangsstufe null ist eine Anlage, die vom Maschinenbediener gesteuert werden kann. Diese Stufe kann so interpretiert werden, dass der Maschinenbediener das alleinige Wissen und die Verantwortung für die Maßhaltigkeit des Prozessausgangs hat und basierend auf diesem Wissen die notwendigen Eingänge des Systems, wie zum Beispiel Positionen, Volumenströme oder ähnliches manuell einstellt. Das System unterliegt somit keinerlei Automatisierung. Problematisch hieran ist, dass bei komplexeren, häufig nichtlinearen Prozessen¹ die Einarbeitungszeit für den Bediener sehr hoch ausfällt und gerade in Zeiten des demografischen Wandels solche Fachkräfte rar sind. Zusätzlich sind solche Prozesse sehr personalintensiv und fehleranfällig. Folglich führen ebenfalls wirtschaftliche Aspekte dazu, dass der Trend zu höher automatisierten Prozessen geht. Auch in der heutigen Produktionslandschaft sind noch viele Prozesse der Automatisierungsstufe 0 anzutreffen aber auch hinreichend robust, um die gewünschten Produkte herzustellen.

¹Eine Änderung der Eingangsgrößen des Systems bewirken ein demgegenüber nicht proportionales Ausgangsverhalten des Systems.




Bild 2-2: Automatisierungsgrad von Produktionsprozessen, nach [DBP⁺ 18]

Robust in diesem Kontext heißt, dass mit einer hohen Prozesssicherheit [Bög09, S. 90] Produkte hergestellt werden können. In der nächsten Stufe und damit ersten Automatisierungsstufe, der assistierten Produktion, wird der Bediener mithilfe von Regelungen der Prozesseingänge unterstützt. Im Gegensatz zur vorherigen Stufe kann er nun die notwendigen Sollwerte der Eingänge vorgeben, also Positionen, Temperaturen o.ä., um den Prozess subjektiv optimal einzustellen. Ebenfalls denkbar in dieser Stufe ist eine „Rezeptverwaltung“, die bekannte Voreinstellungen lädt und (teil-) automatisiert an der Anlage realisiert.

In der Stufe zwei existiert eine grundlegende Automatisierung des Systems insbesondere im Hinblick auf interne Prozessgrößen. Das bedeutet, dass zuvor manuell zu bewältigende Aufgaben bezüglich der Systemeingänge, wie beispielhaft die Zufuhr von Schmiermitteln oder auch einzubringende Kräfte, in dieser Stufe ermittelt, analysiert, bewertet und eingeregelt werden. Grundlage für diese Stufe ist die Existenz von geregelten Aktoren, um die entsprechenden Systemeingriffe zu ermöglichen. Die Qualität der resultierenden Produkte wird in dieser Stufe noch immer von dem Bediener überwacht und falls notwendig korrigierend eingegriffen. In der Regel sind heutige Produktionsprozesse bis einschließlich zu dieser Stufe einzuordnen.

In der Stufe drei, der erweiterten Automatisierung, werden nicht nur die Prozessgrößen in unterlagerten Regelungen eingeregelt, es werden zusätzlich ausgewählte Produktmerkmale mithilfe einer kontinuierlichen Qualitätssicherung erfasst und als Istgrößen für den Prozess genutzt. Der Vorteil hiervon ist, dass das System gegenüber externen Einflüssen robuster wird, da die Abweichungen der Produktmerkmale durch einen geeigneten Regelalgorithmus kompensiert werden. Weiterhin besitzt das System eine inhärente Teilmintelligenz, die die eigenen Systemgrenzen kennt und so einen destruktiven Betrieb des Systems verhindert. Es zeigt sich, dass sich diese Stufe nur in geringem Maße in der aktuellen Produktionslandschaft wiederfindet. Beispielhaft für diese Stufe wurde in [DTB⁺ 14;

BDH⁺12] ein Konzept für ein selbstkorrigierendes Stanz-Biegewerkzeug entwickelt und an einem Beispielprozess validiert. In diesem Konzept wurde die Blechdicke in einem Biegeschritt mithilfe zusätzlicher Sensorik analysiert und im nächsten Biegevorgang bedarfsgerecht korrigierend eingegriffen. Weitere Beispiele für Produktmerkmalsregelungen sind die Regelung von Banddicken beim Walzen [KK08], geometrischen Abmaßen beim inkrementellen Blechumformen [LKL⁺16], Biegewinkeln [vHv15] oder von dreidimensionalen Biegeprozessen [FG14]. Es zeigt sich, dass die Stufe 3 noch momentaner Gegenstand der Forschung ist.

In der Stufe vier, einem hochautomatisierten Prozess, werden alle relevanten Produktmerkmale erfasst. Sie können durch die vorhandenen automatisierbaren Aktoren und der zugehörigen Regelalgorithmik auf ihren Sollwert eingeregelt werden. Es ist ersichtlich, dass die Systeme eine hohe Flexibilität benötigen, da sowohl die Erfassung der Produktmerkmale, als auch die Regelalgorithmik produktindividuell eingestellt werden muss. Insbesondere die Erfassung aller relevanten Produktmerkmale stellt auch heute noch eine große Herausforderung dar. Produktmerkmale können sowohl geometrischer Natur sein, aber auch Materialeigenschaften (wie die Materialhärte, Festigkeit oder ähnliches) beinhalten. Nicht alle Produktmerkmale lassen sich zerstörungsfrei und inline ermitteln. Je nach Ausprägung der Aufgabenstellung kann so von Produkt zu Produkt eine Veränderung der Sollwerte für die Stellgrößen erfolgen oder zum Teil ebenfalls während einer Produktbearbeitung. Zusätzlich wird in dieser Stufe in dem System die Fähigkeit integriert definierte Fehlerbilder selbstständig zu diagnostizieren und zu beheben. Hierbei werden eher einfache Fehler, wie ein verschleißendes Werkzeug, fokussiert. In der letzten Stufe eines vollautomatisierten Produktionsprozesses können zusätzlich nicht von den Entwicklern definierte Fehler vom System selbstständig behoben werden. Das System überwacht eigenständig sein Verhalten und kann so schrittweise die vorhandenen Systemgrenzen erweitern, um die benötigte Produktqualität sicherzustellen. Diese kann vom Produktionsprozess ebenfalls eigenständig erfasst werden, um die selbstlernende Regelung mit den notwendigen Informationen zu versorgen.

Fazit

Es existieren unterschiedliche Produktionsverfahren, die die Grundlage für Produktionsprozesse bilden. Die Motivation dieser Arbeit hat gezeigt, dass die Produktionsprozesse in ferner Zukunft vollautomatisiert ablaufen sollen, sodass kaum Eingriffe von einem Bediener notwendig sind. Diese Stufen der Automatisierung werden in Abbildung 2-2 dargestellt. In der heutigen Zeit werden jedoch in nur sehr wenigen Fällen Produktionsprozesse der Stufe drei (erweitert automatisiert) oder höher betrieben. Die Regelung von Produktmerkmalen ist momentaner Forschungsgegenstand [ADC⁺16].

Es existieren demnach heutzutage zum Großteil Prozesse der Stufen 0 bis 2, die entweder über einen geringen oder mäßigen Automatisierungsgrad verfügen. Maschinen, die wesentlich weiter entwickelt sind, sind häufig Stand der Forschung und haben sehr spezifische Aufgaben, sodass sich der noch notwendige hohe Aufwand lohnt. Die Maschinenbediener werden in der heutigen Zeit immer noch benötigt, um die Maschinen einzurichten und zu betreiben, Systemgrenzen zu berücksichtigen und die Qualität während der Produktion zu überwachen. Ein kurzfristiges Ende




Bild 2-3: Übersicht über die Verfügbarkeitszeit, nach [WD06]

ist aufgrund der komplexen Prozesse nicht abzusehen. Es gilt daher, die Bediener bei den stetig komplexer werdenden Produktionsprozessen in der Übergangszeit von den gering oder mäßig automatisierten Systemen zu den hochautomatisierten Produktionsprozessen bei ihren Arbeiten bestmöglich zu unterstützen.

Die Aufgaben des Mitarbeiters spiegeln sich in der Untergliederung der Maschinennutzungszeit wider. Eine mögliche Sichtweise für die Maschinennutzungszeit wird in [WD06] erörtert (siehe Abbildung 2-3). Die effektive, produktive Maschinennutzung beträgt ungefähr 50% der Maschinenverfügbarkeit und beinhaltet sowohl die Haupt- als auch die Nebenzeiten. Während die Hauptzeiten die eigentliche Wertschöpfung beschreibt, sind die Nebenzeiten notwendige Unterbrechungen des Produktionsprozesses (wie zum Beispiel Ein-, Um- und Ausspannen von Werkstücken oder Werkzeugen, Maschinenbedienung etc.) [Rie51]. Die Ausfallzeiten durch Fehlproduktionen, technisch bedingte Störungen und Wartungen, sowie organisatorischen Stillständen nehmen ca. 23% der Maschinenzeit in Anspruch. Einen wesentlichen Anteil, mit ungefähr 27% der Maschinennutzungszeit, erheben die Umrüstzeiten der Maschinen. Unter dem Umrüsten werden die Arbeiten verstanden, die für die Durchführung eines Produktwechsels auf einer Maschine notwendig sind. Daraus folgend werden in der Produktion

- kurze Bearbeitungszeiten,
- minimale Produktdurchlaufzeiten,
- maximale effektive Nutzungszeiten,
- minimale Rüstzeiten und somit
- schnelle Lieferzeiten angestrebt [WD06].

Während bis vor einigen Jahren die Massenproduktion die Produktionslandschaft dominierte, ist die flexiblere Gestaltung der Produktionen ein momentanes Ziel [LZB17], so dass bereits heute Produkte in steigendem Maße flexibel gefertigt werden [GWHT19]. Zum einen ist dies in einem höheren Bedarf an individualisierten Produkten begründet, aber auch in einem höheren Preisdruck durch die Globalisierung [SGH⁺18]. Dies widerspricht konzeptionell den zuvor erörterten Zielen, wie minimale Rüstzeiten und hohe




Bild 2-4: Zusammensetzung der Stückkosten, nach [WD06]

effektive Maschinennutzungszeiten, da durch eine flexiblere Produktion die Maschinen häufiger die Produkte wechseln und somit die nicht wertschöpfenden Tätigkeiten ebenfalls zunehmen. Der Anteil der effektiven Maschinennutzung sinkt. Um die Rüstkosten zu reduzieren, können höhere Auftragsmengen (Losgrößen) gefertigt werden: hierdurch erhöhen sich jedoch die Lagerkosten, Kapital wird gebunden (siehe Abbildung 2-4) und die Flexibilität sinkt [KS14, S. 45]. Das Ziel ist dementsprechend mithilfe möglichst geringer Bestände wenig Kapital zu binden, Kunden aber trotzdem innerhalb kurzer Zeit zu beliefern [Sys06] und so das Kostenoptimum zu finden [WD06]. Da in den meisten Produktionen nicht für jedes Produkt eine Produktionslinie vorhanden ist, müssen die Produktionslinien stetig neu auf andere Produkte umgestellt werden. Es stellt sich die Frage, inwieweit das Rüsten in der heutigen Zeit noch optimiert werden kann.

Der Rüstprozess

Die Umstellung einer „Anlage vom Produktionsende des gerade produzierten Produkts bis [zu dem] Zustand [...], an dem Gutteile des nächsten Produktes hergestellt [werden]“ [Sys06, S. 128] wird als Rüsten bezeichnet. Der Rüstprozess einer Anlage lässt sich bezüglich des Vorgehens [Rei14] unterteilen in

- die Rüstvorbereitung,
- die Durchführung und
- einer Rüstnachbereitung.

Die Rüstzeit (siehe Abbildung 2-5) setzt sich dabei ungefähr zu 30% aus den vorbereiten- den Tätigkeiten (für das Material, Werkzeuge und Vorrichtungen), zu 5% aus dem Ein- und Ausbau der Werkzeuge, zu 15% aus dem Zentrieren und Einmessen der Werkzeuge und zu 30% aus dem Einrichten zusammen [SRH93, S. 231 ff.]. Diese einzelnen Tätig- keiten lassen sich wiederum in interne und externe Aufgaben unterteilen. Externe Tätig- keiten sind Tätigkeiten, die produktionsbegleitend durchgeführt werden können [KS14]. Beispiele hierfür sind Materialvorbereitungen, eine Einarbeitung in die Dokumentation oder das Beschaffen beziehungsweise das Warten von Werkzeugen. Interne Tätigkeiten




Bild 2-5: Zusammensetzung der Stückkosten, nach [SRH93, S. 231 ff.]

hingegen können nur im Produktionsstillstand durchgeführt werden (Werkzeugwechsel oder das Justieren/Einrichten des Werkzeugs). Wie beschrieben, wird in einer Produktion das Rüsten möglichst vermieden bis zwingend ein anderes Produkt gefertigt werden muss: es gehört zu den nicht-wertschöpfenden Tätigkeiten. Der Zwang ein anderes Produkt zu fertigen begründet sich zum Beispiel durch das notwendige Einhalten von Lieferterminen oder auch durch die Nachproduktion von Zwischenprodukten für nachgelagerte Produktionsschritte.

Um den Rüstprozess zu optimieren, wird unter anderem das Verfahren SMED (engl. *single minute exchange of die*) genutzt, welches sich dediziert mit den in- und externen Rüsttätigkeiten beschäftigt. Die Idee dieser Methode ist, dass möglichst viele Tätigkeiten in die Randbereiche des Rüstprozesses, also der Rüstvor- oder -nachbereitung, verlagert werden. Somit überlappt der Rüstprozess den Produktionsbetrieb und Zeit wird effizient genutzt. Der Rüstprozess wird als ein bedienerabhängiger Prozess beschrieben, der in vielen Fällen unkoordiniert, unorganisiert und unstrukturiert [KS14] abläuft. Aus diesem Grund bietet eine Reorganisation des Prozesses mithilfe der SMED-Methode auch heute noch Potenzial und wird üblicherweise in vier Schritten (siehe Abbildung 2-6) durchgeführt.



Bild 2-6: Vier Schritte der SMED-Methodik zur Optimierung von Rüstprozessen

Der erste Schritt der SMED-Methode ist die Beobachtung des aktuellen Prozesses. Hierfür wird in der Methode eine Videoaufnahme des Rüstprozesses genutzt [SBK14; KS14], um die einzelnen Tätigkeiten zu dokumentieren und den zeitlichen Ablauf zu analysieren. So werden die Mitarbeiter direkt einbezogen [KS14], um gemeinsam den Prozess zu verbessern. Im nächsten Schritt werden die einzelnen Tätigkeiten in interne und externe Aufgaben separiert. Zusätzlich werden unnötige Tätigkeiten identifiziert, um diese im Anschluss zu eliminieren. Nach der Separation der Tätigkeiten können im dritten Schritt

die anfallenden Aufgaben restrukturiert und ggf. angepasst werden. Ziel ist das Umwandeln möglichst vieler interner in externe Aufgaben [MGP⁺18], um so die Stillstandszeit der Anlage zu minimieren. In diesem Schritt kann ggf. ebenfalls der Produktionsprozess selbst angepasst werden, um eine interne in eine externe Aufgabe zu überführen. Im letzten und vierten Schritt werden die Tätigkeiten dann vereinfacht, standardisiert sowie dokumentiert, um mit den Mitarbeitern die neue Vorgehensweise zu trainieren [KS14] und das neue Vorgehen zu etablieren.

Die Methode wird nach wie vor angewendet, um unterschiedliche Produktionsprozesse zu optimieren [SBK14]. In [SSF⁺18] wurde mit der SMED-Methode der Rüstprozess eines Korkenherstellers optimiert. Hierzu wurden die vier Schritte durchlaufen und die Anlagen ebenfalls erweitert, um interne Aufgaben umzuwandeln. Alles in allem konnte somit die ursprüngliche Gesamtrüstzeit von 66 Minuten um 43% reduziert werden. Ähnlich erfolgreiche Ergebnisse konnten in [MGP⁺18] oder auch [BRCG17] erzielt werden.

Obwohl das Rüsten ein produktionsinhärenter Prozess ist und seit Anbeginn der industriellen Produktion durchgeführt wird, bietet er auch in der heutigen Zeit noch vielfältige Optimierungspotenziale (siehe Abbildung 2-5). Ein vorhandenes Potenzial, die Strukturierung des gesamten Rüstprozesses, wird von der SMED-Methode genutzt. Auch die einzelnen Tätigkeiten selbst, wie das Einarbeiten in die Dokumentation, dem Kalibrieren von Messmitteln oder auch das Einrichten bieten noch Optimierungspotenzial. Auch in diesen Schritten kann der Bediener besser bei seinen Aufgaben unterstützt werden [KS14, S. 44]. Im Folgenden wird daher das Einrichten als Teil des Rüstens näher beleuchtet und das Potenzial aufgezeigt.

2.2 Das Einrichten von Produktionsprozessen

Das Einrichten von Produktionsprozessen hat die Aufgabe die gewünschten Eigenschaften der zu produzierenden Produkte sicherzustellen. Hierbei wird der Produktionsprozess mithilfe der Justagemöglichkeiten auf die aktuellen Umwelteinflüsse eingestellt, um die notwendige Produktqualität zu gewährleisten. Beispiele für Justagemöglichkeiten sind Stellschrauben, Maschinenparameter oder auch äußere Einflüsse, wie die Umgebungstemperatur. Umwelteinflüsse zeichnet aus, dass diese die gewünschte Qualität der Produkte beeinflussen und in ihrem Verhalten nicht vorhergesagt [FKL⁺13] oder beeinflusst werden können. Beispiele hierfür können der Schmierzustand, Temperaturen oder auch Materialeigenschaften sein. Umwelteinflüsse oder Störungen können ebenfalls in ihrer Messbarkeit differieren. Bei dem Einrichten ist es unerheblich, wie (d.h. manuell, gesteuert oder geregelt) die Merkmale eingestellt werden - auch eine Regelung, die beim Produktionsstart die notwendigen Justagemöglichkeiten variiert, kann zum Einrichten zugezählt werden.

Produktionsprozesse werden nach wie vor in vielen Fällen manuell eingerichtet. Schematisch ist dieser Prozess in Abbildung 2-7 illustriert. Bei dem momentan üblichen Prozess ist der Maschinenbediener die zentrale Einheit und kann als Regler verstanden werden. Für die Produkte werden während der Entwicklung Merkmale definiert, die dem Bediener als Ziel dienen. Während des Einrichtprozesses werden die Merkmale von dem Maschinenbediener häufig intuitiv gegeneinander abgewogen und priorisiert. Aufgrund der Abhängigkeit der Merkmale voneinander muss er häufig einen Kompromiss zwischen




Bild 2-7: Schema des Einrichtprozesses - nach [GSH⁺ 18]

diesen finden. Der Maschinenbediener baut über Versuch und Irrtum oder einer Dokumentation des Produktionsprozesses das notwendige Fachwissen auf und nutzt dieses für den Einrichtprozess. Der Maschinenbediener fungiert demnach ähnlich wie ein modellprädiktiver Regler (MPR), der mithilfe eines Prozessmodells „ideale“ Justagen für den Produktionsprozess ermittelt und diese anschließend appliziert, sowie die Änderungen der Qualitätsmerkmale evaluiert. An dieser Analogie zeigt sich, wie wichtig der Maschinenbediener in dem momentanen Prozess ist. Auch bei einem MPR ist das Modell von essenzieller Bedeutung, welches beim Einrichten dem Prozesswissen des Maschinenbedieners entspricht.

Häufig werden im Vorfeld einmalig funktionale Justagen ermittelt und zentral abgelegt [KS14, S. 11] und dienen dem Maschinenbediener als Startpunkt für die Optimierung. Es wird dem Mitarbeiter überlassen diese in geringem Maße zu variieren, um die letzten Schritte zur optimalen Qualität durchzuführen. Analog zu einem Regler führt der Maschinenbediener hierbei ebenfalls einen Soll-Ist-Vergleich der Qualitätsmerkmale durch und kompensiert so die momentan anliegenden Unsicherheiten im Prozess. Dieses inkrementelle Einrichten kann je nach System mehrere Iterationen benötigen. Aufgrund der steigenden Komplexität der Produktionsprozesse und den hohen Qualitätsanforderungen, stellt dieser Prozess ein zeit- und damit kostenintensives Vorgehen dar. Insbesondere bei preisintensiven Produkten ist aufgrund wirtschaftlicher Betrachtungen ersichtlich, dass die Anzahl der Iterationen auf ein Minimum reduziert werden muss. Im Folgenden wird die oben beschriebene initiale Startparameterermittlung verschiedener Prozesse anhand der Literatur erörtert und abschließend ein Fazit abgeleitet.

Anwendungsbeispiele für initiales Einrichten

In vielen Fällen wird bei der initialen Inbetriebnahme des Produktionsprozesses ein funktionsfähiger Parametersatz ermittelt. Funktionsfähig heißt, dass mit diesem Parametersatz Produkte in benötigter Qualität hergestellt werden können. Insbesondere wenn bei der Ermittlung guter Startparameter eine methodische Unterstützung fehlt, existiert Optimierungspotenzial bezüglich der Produktqualität. So wurde in [AA13] die Qualität des **Tieflochbohrers** optimiert und ein für den Prozess optimierter Parametersatz gefunden. Die Qualität des Prozesses wurde hierbei durch die Rundheit, die Zylindrizität, dem Durchmesser und der Rauigkeit der Bohrung charakterisiert. Basierend auf der statistischen

Versuchsplanung wurden daher Experimente durchgeführt und ein analytisches Modell berechnet, um die Prozessparameter Drehgeschwindigkeit, Vorschub und inkrementelle Bohrungstiefe zu optimieren. Mithilfe einer Optimierung einer skalaren Zielfunktion

$$J = \sqrt{\prod_{i=1}^n y_i}$$

mit gleichgewichteten, normierten Produktmerkmalen y_i , konnte folglich ein optimaler Parametersatz berechnet werden. Neben der gleichgewichteten Zielfunktion wurde zusätzlich eine exponentiell gewichtete Zielfunktion

$$J = \sqrt[\sum r_i]{\prod_{i=1}^n y_i^{r_i}}$$

untersucht und vorgestellt.

Ein ähnlicher Ansatz wurde in [AH15] gewählt. Hier wurde für einen **inkrementellen Blechumformungsprozess** (engl. *single-point incremental forming*) untersucht, wie sich die Prozessparameter auf die Umformkraft auswirken. Ziel war eine Minimierung der notwendigen Kraft beim Prozess, um das Material und das Werkzeug zu schonen. So wurden ebenfalls Experimente durchgeführt, die auf Basis der statistischen Versuchsplanung vorbereitet wurden. Fünf Prozessparameter,

- Blechdicke,
- Werkzeugdurchmesser,
- Anstellwinkel,
- Zustellung und
- Fließspannung,

wurden bezüglich des Einflusses auf die Qualitätsmerkmale, bestehend aus den Prozesskräften, untersucht. Die an dem Werkzeug anliegenden Prozesskräfte der drei Raumrichtungen wurden geometrisch zu einer resultierenden Kraft

$$J = \sqrt{y_1^2 + y_2^2 + y_3^2}$$

aggregiert. Diese wurde direkt als Zielfunktion für eine Optimierung genutzt. Regressionsmodelle wurden berechnet, um Prozessparameter mit möglichst geringer Prozesskraft zu ermitteln. Ein ähnlicher Ansatz ist für den Produktionsprozess in [DK19] zu finden. In [Bam08] wurde der Prozess mit der Finite Elemente Analyse untersucht und hinsichtlich definierter Qualitätsmerkmale optimiert. Als wesentliches Qualitätsmerkmal wurde eine homogene Blechdicke [Bam08, S. 154f.] über das gesamte FE-Bauteil betrachtet. Mithilfe einer numerischen Optimierung konnten so optimierte Trajektorien für das Werkzeug berechnet werden.

In [KAS⁺16] wurde ein **Kriechumformprozess** (engl. *creep age forming*) für ein Testbauteil aus einer Aluminiumlegierung hinsichtlich der Prozessparameter untersucht und optimierte Parameter ermittelt. Als Optimierungsparameter wurden die Haltezeit und die Bauteiltemperatur identifiziert, um das Rückfederverhalten des Prozesses abzubilden. Es




Bild 2-8: Expertensystem zur Prozesseinrichtung, nach [TEGP13]

wurde ein effizient zu optimierendes Regressionsmodell berechnet und darauf aufbauend ein funktionsfähiger Parametersatz gefunden. Dieser wurde manuell mithilfe eines Contour-Plots ermittelt, indem die Parameterkombinationen von Interesse eingegrenzt und die Solleigenschaften des Produkts abgeglichen wurden.

Neben den hier beschriebenen Anwendungen zum Ermitteln funktionsfähiger, optimaler Parameter für einen Produktionsprozess, existieren eine Vielzahl weiterer Beispiele in der Literatur². Diesen Beispielen ist gemein, dass an einem System, ausgeführt als realer Prozess oder auch Simulationsmodell, Experimente durchgeführt und Modelle entwickelt werden. Diese werden anschließend zur Berechnung der optimierten, funktionsfähigen Prozessparameter genutzt. Hierbei zeigt sich, dass die Definition der Gesamtqualität anhand der einzelnen Qualitätsmerkmale nicht einheitlich geschieht, sondern je nach Veröffentlichung variiert. Das bedeutet, dass je nach Anwendungsfall eine andere Metrik für die Beschreibung der Qualität genutzt wurde. Ein einheitliches, allgemeingültiges Vorgehen auch für die Gewichtung der Teilziele ist nicht erkennbar.

Einen Schritt weiter geht [TEGP13]: in der Veröffentlichung wird ein Expertensystem (siehe Abbildung 2-8) zur Identifikation von funktionsfähigen Prozessparametern beschrieben. Das entwickelte System nutzt Versuchsdaten, um eine symbolische Regression für das Ein-/ Ausgangsverhalten des betrachteten Zielsystems zu berechnen. Das Ergebnis dieser Regression (näheres zum Beispiel in [Klo18, S. 497]) ist ein mathematisches Modell, welches nach einer Validierung in einer mithilfe von Bewertungskriterien adaptierbaren Zielfunktion genutzt wird. Durch den Einsatz evolutionärer Optimierungsalgorithmen wird ein Parametersatz berechnet, der in dem Zielprozess genutzt werden kann. Für die Validierung des Systems wurden als Zielprozess eine **Dreh- und Fräsmaschine** herangezogen. Hierbei hat sich wie erwartet gezeigt, dass die Modelle möglichst vollständig sein müssen, um einen hinreichend funktionsfähigen Parametersatz zu berechnen.

²Weitere Beispiele sind [AGJ10; AP18; BPMH07; JJC⁺16; JS10; KJ15; KB16; SFMW18; TNW⁺16; VMV⁺16]

Die Veröffentlichung zeigt, dass ein generalisierbares Vorgehen fehlt, welches auch mit unerwarteten, nicht messbaren Einflüssen umgehen kann. Hierbei ist von Bedeutung, dass nicht nur Experten für die Methodiken dieses System benutzen können, sondern ebenfalls die Maschinenbediener, die für das Einrichten der Prozesse zuständig sind. Wenn solche komplexe Sachverhalte nutzerfreundlich aufbereitet werden, wird von Assistenzsystemen gesprochen. Diese werden im nächsten Abschnitt näher erläutert.

2.3 Assistenzsysteme in der Produktion

Nachdem Produktionsprozesse und speziell das Einrichten erörtert wurden, werden in diesem Abschnitt Assistenzsysteme in der Produktion näher beleuchtet. Insbesondere durch die Hightech-Strategie „Industrie 4.0“ der deutschen Bundesregierung sind solche Assistenzsysteme in den Fokus der Wissenschaft und Unternehmen gelangt. Die Ziele und Ausprägungen von Assistenzsystemen in der Produktion sind vielfältig, daher werden für diese Arbeit im ersten Schritt übliche Charakterisierungen, also Klassifikationssystematiken, vorgestellt und anschließend ein Überblick über vorhandene Assistenzsysteme in der Forschung gegeben. Häufig setzen diese Systeme auf die Auswertung von Produktionsdaten, sodass im nächsten Abschnitt (siehe Abschnitt 2.4) häufig genutzte datengetriebene Analyseverfahren beschrieben werden.

2.3.1 Klassifikation der Assistenzsysteme

In diesem Abschnitt werden unterschiedliche vorhandene Klassifikationsansätze für Assistenzsysteme erörtert. Zunächst wird ein Konzept von [ABP⁺18] aus Sicht der Digitalisierung der Arbeitswelt unter Berücksichtigung der Assistenzsysteme vorgestellt. Dieses wird durch eine Klassifikationssystematik aus Sicht der Arbeitsgestaltung [CSS18] ergänzt. Darauf aufbauend werden Assistenzsysteme zur Entscheidungsunterstützung aus Sicht der Logistik [BCK⁺07] näher beleuchtet und abschließend die Sicht der assistierten Produktionsprozesse vorgestellt.

Sicht der Arbeitsgestaltung

Eine Sicht auf Assistenzsysteme ist unter dem Stichwort der Arbeit 4.0 situiert und spiegelt die Sicht der zukünftigen Arbeitsgestaltung wieder. Durch die fortschreitende Digitalisierung der Gesellschaft und auch der Produktion ändert sich die Art, wie ein Individuum in Unternehmen mit Menschen und Maschinen interagiert grundlegend. Eine Ausprägung der Arbeitsweise wird durch die Assistenzsysteme in der Produktion definiert. Nach [ABP⁺18, S. 19] lassen sich solche Assistenzsysteme nach dem Grad, der Art und dem Ziel der Unterstützung unterteilen (siehe Abbildung 2-9). Diese Klassifikationssystematik wird folgend genauer vorgestellt. Es wird postuliert und plausibilisiert, dass die Unterstützung der Mitarbeiter aus unterschiedlichen Zielsetzungen motiviert sein kann. So kann das System die menschlichen Fähigkeiten und die Gesundheit kompensatorisch, erhaltend oder erweiternd unterstützen [ABP⁺18, S. 29]:

- Kompensatorische Systeme können zum einen generelle Schwächen des menschlichen Körpers ausgleichen oder inklusives Arbeiten ermöglichen.

Digitale Assistenzsysteme in der betrieblichen Praxis		
Zielsetzung der Unterstützung	Art der Unterstützung	Grad der Unterstützung
kompensatorisch	physisch	Niedrig
erhaltend	sensorisch	Mittel
erweiternd	kognitiv	Hoch
		Variabel

Bild 2-9: Klassifikationssystematik der Assistenzsysteme, nach [ABP⁺18, S. 19]

- Erhaltende Systeme adressieren das gesunde Arbeiten, indem eine Überbelastung des Bewegungsapparats vermieden wird.
- Fähigkeitserweiternde Systeme verbessern oder erhöhen die Produktivität des menschlichen Körpers über das Normalmaß hinaus. Die Abgrenzung zu kompensatorischen Systemen ist hierbei fließend.

Die Art der Unterstützung lässt sich wiederum in physische, sensorische und kognitive Unterstützung unterteilen. Bei der physischen Hilfestellung durch die Assistenzsysteme wird der Mitarbeiter bei körperlichen Tätigkeiten, wie das Heben schwerer Lasten, entlastet. Es können auch altersbedingte Nachteile durch ein assistierendes System ausgeglichen werden. Beispiele sind explizit Exoskelette, kollaborative Robotersysteme oder auch Montagearbeitsplätze. Unter sensorischer Unterstützung verstehen die Autoren die Unterstützung der menschlichen Wahrnehmung über die Sinnesorgane. Hierzu kann ein Hörgerät zum Ausgleich eines altersbedingten Verlusts des Hörsinns. Speziell im Produktionsbetrieb sind Augmented-Reality-[NS18; MPRC13] oder auch Pick-by-Light-Anwendungen [FSM⁺15] Gegenstand aktueller Forschung. Bei kognitiven Unterstützungen wird der Mensch durch ein System in seinen notwendigen Entscheidungen unterstützt. Die Unterstützung ist bei solchen Systemen auf die „Reaktions-, Denk-, Merk- und Schlussfolgerungsfähigkeit“ [ABP⁺18, S. 21] ausgerichtet. In der Veröffentlichung werden vor allem mobile Endgeräte und Visualisierungen als Hardware-Grundlage angegeben.

Der Unterstützungsgrad wird in [ABP⁺18] mit der Aufgabenkomplexität korreliert. So wird zwischen niedrigem, mittlerem, hohem und variablem Unterstützungsgrad unterschieden. Hierbei wird der niedrige Grad zu mechanischer und motorischer Arbeit zugeordnet: beispielhaft sind assistierte Bewegungsabläufe diesem Bereich zugehörig. Zu einem mittleren Unterstützungsgrad werden reaktive Arbeiten, zum hohen Unterstützungsgrad kombinatorische und zum variablen Unterstützungsgrad kreative Arbeiten zugeordnet. Hierbei steigt die erforderliche kognitive Leistung von niedrig zu variabel an [ABP⁺18, S. 23].

Einen weiteren Blickwinkel aus Sicht der Arbeitsgestaltung (siehe Abbildung 2-10) bringt [CSS18] ein. Die physisch und kognitiv unterstützenden Systeme sind äquivalent zu den




Bild 2-10: Klassifikationssystematik aus Sicht der Arbeitsgestaltung, nach [CSS18, S. 39]

Kategorisierungen von [ABP⁺18] zu betrachten. Zusätzlich werden jedoch noch drei weitere Assistenzsystemarten identifiziert [CSS18, S. 39]: Die interaktionsunterstützenden Systeme assistieren dem Menschen bei der direkten Zusammenarbeit mit Maschinen. Hierzu werden Feedback-Systeme aber auch Interaktionsmodelle für Mensch-Maschine-Schnittstellen aufgeführt. Von den physisch unterstützenden Systemen werden die Service- und Assistenzroboter abgegrenzt. Hierbei wird unterschieden, dass der Mensch durch eine externe, nicht mit dem Körper verbundene Einheit, wie einem kollaborativen Roboter, entlastet wird. Beispielhaft werden Inspektions-, Service- oder Produktionsassistenzzroboter aufgeführt. In [ABP⁺18] würden diese Assistenzsysteme unter physische Assistenzsysteme mit in der Regel niedrigem Unterstützungsgrad zusammengefasst. Als letzte zusätzlich identifizierte Kategorie werden die psychisch unterstützenden Systeme aufgeführt. Unter diesen werden Assistenzsysteme verstanden, die die Vitaldaten der Zielperson erfassen. Hierzu zählen beispielsweise Fitnessarmbänder oder auch Smartwatches („Wearables“). Ein Äquivalent in [ABP⁺18] wäre eine sensorische Unterstützung mit mittlerem bis hohem Unterstützungsgrad mit dem Ziel die Gesundheit des Trägers zu erhalten.

Sicht der Logistik

Neben der reinen Sicht auf den Menschen kann ebenfalls die Unterstützung in komplexen Materialflussprozessen mit Assistenzsystemen betrachtet werden. So werden in [BCK⁺07] Assistenzsysteme für die Entscheidungsunterstützung für Logistiksysteme klassifiziert. Es wird definiert, dass das Assistenzsystem das Leistungspotenzial aus der Fähigkeit bezieht „intelligente Prozeduren durchzuführen, bei deren Ausführung die Menschen angesichts hoher Schwierigkeitsgrade und (System-)Komplexitäten aufgrund ihrer begrenzten kognitiven Fähigkeiten systematisch scheitern“ [BCK⁺07, S. 7]. Zur Klassifikation unterscheiden die Autoren hier explizit zwischen der Unterstützungsart und der Arbeitsteilung zwischen Mensch und Maschine.

Bei der Unterstützungsart wird in [BCK⁺07, S. 7] zwischen sechs Kategorien differenziert, die eine stetige Komplexitätssteigerung ausweisen. Die erste Stufe ist das „Erzeugen und Aufbereiten von Informationen“, welche sowohl die Datenakquise als auch eine erste Analyse beinhaltet, um den Bediener zu unterstützen. In der zweiten Stufe, dem „Erzeugen von Alternativen“ werden die Daten so weiterverarbeitet, dass dem Menschen Handlungsalternativen vorgeschlagen werden. Die Alternativen werden in der dritten Stufe „Bewertung von Alternativen“ mithilfe einer Metrik miteinander vergleichend darge-

stellt. Basierend darauf wird in der nächsten Stufe dem „Auswählen von Alternativen“ abgewägt und das Ergebnis dem Bediener präsentiert. Der Bediener erhält somit einen Handlungsvorschlag, ist aber noch frei in der Umsetzung. Diese Freiheit wird in der fünften Stufe „Überwachen/Monitoring der Entscheidungsausführung“ eingeschränkt, da seine Entscheidung mithilfe von zuvor identifizierten Beschränkungen und Zielvorgaben überwacht wird. Die letzte darauf aufbauende Stufe „Kontrollieren der Entscheidungsausführung“ überprüft die Entscheidung des Menschen und bindet ihn mit Teilaufgaben in den Entscheidungsprozess ein, dies kann soweit führen, dass ihm ebenfalls eine getroffene Entscheidung zur Revision vorgelegt wird.

Die Unterstützungsart wird durch eine weitere Dimension, der „Arbeitsteilung zwischen Mensch und Maschine“ [BCK⁺07, S. 9] ergänzt. Bei dieser Dimension wird angemerkt, dass sie für jede der Unterstützungsarten gilt und eine unterschiedliche Ausprägung aufweisen kann. So wird zwischen „Rechner“, „verteilt“ und „Mensch“, also automatisierter, teilautomatisierter und manueller Arbeitsweise differenziert. Da beispielhaft ein Assistenzsystem der Stufe 3 auch auf den vorherigen Stufen aufbaut, kann diese Dimension für ein Assistenzsystem je Stufe angewendet werden.

Sicht der Produktionsprozesse

In [Sch15] werden speziell Assistenzsysteme in der Betriebsphase von Produktionsprozessen in Hinblick auf ihre technologische Umsetzung klassifiziert (siehe Abbildung 2-11). Neben der Art der Assistenzsysteme werden als zusätzliche Dimensionen Parameter und Ausprägungen der Unterstützungen identifiziert. So wird hier zwischen informationstechnischen, körperlichen und kognitiven Systemarten, in der Veröffentlichung „Parameter“ genannt, unterteilt. Während der physische und der kognitive Aspekt durchgängig in den bereits beschriebenen Kategorisierungen vorhanden ist, lassen sich die informationstechnischen Systeme eher zu den interaktionsunterstützenden Systemen aus [CSS18] zuordnen. Die vorgestellte Unterteilung lässt sich hierbei nicht nur für industrielle Produktionsprozesse nutzen, sondern kann ebenfalls zur Klassifikation in der Militärtechnik genutzt werden.

Die informationstechnischen Assistenten werden in informationsbereitstellende und -rückmeldende Systeme unterteilt [Sch15, S. 369]: diese Art dient in erster Linie dem Informationsaustausch mit dem Produktionsprozess. So wird zwischen der Kommunikation vom Menschen zur Maschine (informationsrückmeldend) und von der Maschine zum Menschen (informationsbereitstellend) unterschieden. Letzteres erfolgt laut Autoren in der Produktion überwiegend visuell, da so zum einen viele Informationen vom Menschen gleichzeitig erfasst, sowie verarbeitet werden können. Zum anderen sind weniger Störeinflüsse als bei anderen Kommunikationskanälen vorhanden. Eine akustische Rückmeldung von der Maschine ist in der Regel auf Bestätigungs- oder Alarmsignale beschränkt. Weiterhin können komplexe Handlungsanweisungen schwieriger zum Beispiel in natürlicher Sprache beschrieben werden. Die Informationsrückmeldung vom Menschen zur Maschine wird beispielhaft in mehreren technologischen Ausprägungen wie Barcodes, RDID-Chips oder auch Touch-Screens ausgeprägt. Häufig werden diese Assistenzsysteme genutzt, um den Nutzer durch eine schrittweise Informationsbereitstellung durch einen komplexeren Maschinen- oder Softwareprozess zu führen.




Bild 2-11: Kategorisierung der Assistenzsysteme in der Betriebsphase, nach [Sch15, S. 370]

Die körperlichen Assistenzsysteme [Sch15, S. 369] werden nicht weiter unterteilt, aber in unterschiedliche Ausprägungen technologisch differenziert. So kann laut der Veröffentlichung der Mensch mithilfe von

- Förder- und Hebetechnik,
- Manipulatoren,
- Exoskeletten oder auch
- Roboter

unterstützt werden. Während die Beispiele der Exoskelette und der Roboter aus den vorherigen Klassifikationssystematiken bereits bekannt sind, sind die ersten beiden Ausprägungen noch nicht adressiert. Als Beispiel für assistierte Transportsysteme wird das intelligente Routing anhand aktueller Produktionsauslastungen aufgeführt. Beispielhaft für Manipulatoren werden Montageassistenten aufgeführt, welche anhand ihrer Position im Raum das Drehmoment des Schraubers einstellen.

Bei den kognitiven Assistenzsystemen wird zwischen der Informations- und Situationsaufnahme differenziert. Dies impliziert, dass diese Systeme in diesem Modell stets einen aktiven Anteil einnehmen, im Gegensatz zu den informationstechnischen Systemen, und sich damit abgrenzen. Aktiv bedeutet in diesem Fall, dass eine Sensorik für die Informationsbeschaffung integriert ist und der Mensch keinen Eingriff tätigen muss. Die Informationsaufnahme kann technologisch beispielhaft über Kamerasysteme, Kameras mit Tiefeninformationen („3D-Kameras“), über Funk (zur Ortung des Werkzeugs), über Körperschallsensorik [Bay23] oder über Systemmodelle (zum Beispiel CAD-Daten) erfolgen. Nach der Situationsaufnahme erfolgt eine Analyse bezüglich der Systemziele und ein anschließender Eingriff in das System. Diese Analyse erfolgt mithilfe bedarfsgerechter Modelle, die entweder die Wahrnehmung des Menschen, seinen Lernfortschritt, Wissen über den Prozess oder auch Handlungsstrategien enthalten. Auch in der Militärtechnik werden vermehrt kognitive Assistenzsysteme eingesetzt, da die Aufgaben der Besatzungen zunehmend an Komplexität gewinnen. Ein Beispiel ist das „Cognitive Cockpit“ (COGPIT),




Bild 2-12: Klassifikation von Assistenzsystemen anhand von Komplexitätsstufen, nach [KKM⁺17, S. 267]

welches den Helikopterpiloten dabei unterstützt seine Aufmerksamkeit zur richtigen Zeit auf die relevanten Ereignissen zu lenken [And13, S. 42]. Auch im Bereich der unbemannten Flugobjekte werden kognitive Assistenzsysteme eingesetzt: Das System „Intelligent Aiding“ unterstützt den Piloten mehrerer Flugobjekte bei der Identifikation von kognitiv anspruchsvollen Situationen. Diese Situationen treten durch die Notwendigkeit von gleichzeitigen Interaktionen auf. Durch die Identifikation dieser Zeiten kann der Pilot im Vorfeld Gegenmaßnahmen ergreifen, um diese zu entzerren [And13, S. 45].

In [KKM⁺17] werden Assistenzsysteme nach Komplexität und Ausprägung der Komponenten klassifiziert. Die betrachteten Systeme sind im Bereich der Produktionsprozesse situiert. Wie in Abbildung 2-12 zu sehen, erfolgt die Einteilung der Assistenzsysteme nach Komplexitätsstufe. Die Unterteilung erfolgt dabei eindimensional in 4 Stufen:

1. Signalisierung,
2. Beobachtung,
3. Prognose und
4. Unterstützung.

Die erste Stufe, die Signalisierung, beschreibt dabei die Systeme, die die aktuellen Systemzustände visualisieren ohne diese zu interpretieren. Der Maschinenbediener kann diese entsprechend analysieren und aufgrund seines Erfahrungswissens Handlungsmöglichkeiten ableiten. Ein eingängiges Beispiel ist der Ölfüllstand einer Maschine, der durch den Bediener überwacht wird. Bei Unterschreitung eines vom Bediener festgelegten Grenzwerts ist er durch das System in der Lage bedarfsgerecht Öl nachzufüllen. In der zweiten Stufe, der Beobachtung, wird ebenfalls der Zustand überwacht, jedoch erfolgt durch das Assistenzsystem bereits eine Klassifikation in zulässigem und unzulässigem Systemverhalten. Eine Überschreitung einer im System hinterlegten Toleranzschwelle führt zu einer Benachrichtigung des Maschinenbedieners. Am Beispiel des Ölstands ist ein Aufblinken einer Warnleuchte bei Unterschreitung einer definierten Füllstandshöhe möglich.

Die dritte Stufe wird nach [KBA⁺14, S. 268] als Prognose klassifiziert und enthält neben den direkten Prozessgrößen ebenfalls indirekte Prozessgrößen. Diese werden den Autoren nach von dem Assistenzsystem zu Ursache-Wirkungszusammenhängen modelliert und stehen folglich dem Bediener zur Verfügung. Dieser kann basierend auf den Prognosen, wie sich der Prozess verändern wird, das Maschinenverhalten nach eigenem Ermessen




Bild 2-13: Aktueller Stand der Assistenzsysteme, nach [KKM⁺17, S. 270]

adaptieren. An diesem Punkt setzt die vierte Stufe, die Unterstützung, an und zeichnet sich durch eine maximale Informations- und Interpretationsdichte aus. Diese Informationen werden, wie in der dritten Stufe, zu Ursache-Wirkungsmodellen zusammengeführt und durch das Assistenzsystem weiterverarbeitet. Die Weiterverarbeitung erfolgt dahingehend, dass wie zuvor das Systemverhalten prognostiziert wird, aber nun dem Bediener Handlungsempfehlungen, also Vorgaben, für einen optimalen Prozess gegeben werden. Es wird in der Veröffentlichung angemerkt, dass die Assistenzsysteme der dritten und vierten Stufe aufgrund ihrer hohen Komplexität kaum in der Produktion Anwendung finden.

Der spezifische Grund für die geringe Anwendung dieser Assistenzsysteme ist in Abbildung 2-13 zu sehen. In der Abbildung ist eine Bewertung des Stands der Technik für heutige Assistenzsysteme abgebildet. In dem Schaubild wird unterschieden, welche Tätigkeiten welchem Automatisierungsgrad unterliegen. Der Automatisierungsgrad gliedert sich von einer rein manuellen Tätigkeit durch den Menschen bis zu einer vollautomatisierten, also allein technischen Lösung. Die Entwicklung von Assistenzsystemen besteht demnach aus drei Komponenten, die unter Berücksichtigung der Komplexitätsstufe unterschiedlich hohem Entwicklungsaufwand unterliegen:

1. der Datenaufnahme,
2. der Datenverarbeitung und -analyse sowie
3. der Ergebnisumsetzung.

Die Datenaufnahme mithilfe verschiedener am Markt erhältlicher Sensorik, sowie die Ergebnisumsetzung durch vielfältige Aktoren sind bereits heute durch einen hohen Automatisierungsgrad gekennzeichnet. Dem gegenüber steht die Datenverarbeitung und -analyse, die in der heutigen Zeit noch einen hohen manuellen Aufwand durch den Menschen erfordert. Für diese Komponente ist das Ziel die „kognitive[n] Fähigkeiten des Menschen“ [KKM⁺17, S. 270] bezüglich der Analysemöglichkeiten nachzubilden und idealerweise zu übertreffen. Es zeigt sich in der Grafik, dass mindestens eine Ausprägung von Datenaufnahme, Datenverarbeitung und Ergebnisumsetzung noch eine partiell menschliche Komponente haben muss, um in den Bereich der Assistenzsysteme zu fallen.

Fazit

Im letzten Abschnitt wurden unterschiedliche Klassifikationssystematiken für eine Charakterisierung von Assistenzsystemen vorgestellt. Die Kategorisierung erfolgt je aus einem spezifischen Blickwinkel und legt unterschiedliche Schwerpunkte auf zum Beispiel Technologien oder die Arbeitsplatzgestaltung. Den Klassifikationssystematiken gemein ist die Differenzierung unterschiedlicher Komplexitätsstufen für die Assistenzsysteme und die Berücksichtigung verschieden ausgeprägter Zielsetzungen. Für die Systematik des Einrichtungssystems werden die verschiedenen Facetten der Klassifikation benötigt, daher wird für die vorliegende Arbeit in Abschnitt 3.2 basierend auf den erörterten Klassifikationssystematiken eine eigene entwickelt. Das Ziel ist, das in dieser Arbeit entwickelte Assistenzsystem vor der Entwicklung präzise zu charakterisieren und Vergleiche, aber auch Abgrenzungen zu anderen Systemen aufzuzeigen. Als weitere Grundlage für diesen Schritt werden nun vorhandene Assistenzsysteme aus dem Produktionsbereich vorgestellt.

2.3.2 Assistenzsysteme in der Produktion

Nach der Untersuchung unterschiedlicher Ausprägungen der Assistenzsysteme in der Produktion und angrenzender Bereiche werden im Folgenden relevante Beispiele für in der Wissenschaft oder Industrie vorhandene Assistenzsysteme im Bereich des Rüstens oder Einrichtens vorgestellt.

Bereits in Abschnitt 2.2 wurde bei den Beispielen aus der Wissenschaft ein Ausblick auf ein Expertensystem gegeben [TEGP13], welches ebenfalls als Assistenzsystem für eine **Dreh- und Fräsanlage** ausgeführt ist. Wie beschrieben ermöglicht die vorgestellte Architektur die Ermittlung optimaler Parameter für einen Referenzprozess. Hierfür werden Modelle mithilfe einer symbolischen Regression berechnet und in einer Mehrzieloptimierung genutzt. Durch den Einsatz evolutionärer Algorithmen kann dann der ideale Parametersatz gefunden werden. In dem Projekt „Cyberrüsten 4.0“ [DHK⁺16] wird das Rüsten und Einrichten einer **Rohrbiegemaschine** unterstützt. Hierfür wurde im ersten Schritt der Gesamtprozess des Rüstens mithilfe von Interviews und Beobachtungen analysiert und der Prozess unter Einbezug einer FE-Simulation untersucht. Die aus der Analyse gewonnenen Erkenntnisse werden dem Bediener übersichtlich aufbereitet über eine Mixed-Reality-Brille angezeigt. Angezeigte Informationen sind die notwendigen Arbeitsschritte in qualitativer Form, unterstützt durch zum Beispiel Videos. Perspektivisch soll die erarbeitete Methodik auch auf weitere Produktionsprozesse übertragen werden: bei der Biegemaschine konnten Rüstzeitreduktionen durch die präziseren Anweisungen von bis zu 50% erreicht werden. [Tre18]

Ein weiteres Beispiel ist das Projekt „APPsist“, welches sich mit „kontextsensitiven, intelligent-adaptiven Assistenzsystemen zur Wissens- und Handlungsunterstützung für die Industrie 4.0“ [WH18] beschäftigt. Das Projekt umfasst neben der technischen Umsetzung auch eine vorgeschlagene Vorgehensweise: Zunächst werden in dem Forschungsprojekt die Zielprozesse mithilfe von Workshops mit den Experten zusammen erörtert. Anschließend werden die Prozesse mit der Business Process Model and Notation (BPMN) abgebildet und die relevanten Prozessschritte und zielgruppenindividuellen Anwendun-




Bild 2-14: Architektur des Assistenzsystems aus APPsist, nach [PKK17]

gen konserviert. Jede notwendige Maßnahme besteht aus Aktivitäten, die in Aktionen und elementaren Schritten untergliedert sind. Im letzten Schritt werden jeder Ebene anschließend Assistenzinhalte zugeordnet. Anzeigeelemente im Fall dieses Projekts sind Texte, Symbole, Bilder, technische Zeichnungen oder auch AR-Inhalte [WH18].

Diese so ausdetaillierten Lerndaten (siehe Abbildung 2-14) werden in einer semantischen Datenbank mit einer Ontologie gespeichert, sodass das APPsist-System darauf zugreifen kann [PKK17]. Das System ist in der Lage unterschiedliche Anzeigeelemente, wie Tablets, Smart Watches oder auch AR-Brillen, zu bedienen, mit denen der Bediener interagiert (HCI: human computer interaction), um eine Aufgabe zu lösen. Beispielhafte Aufgaben sind das Einrichten, Wartungsarbeiten oder auch der Produktionsbetrieb. Dem Bediener werden so die notwendigen Informationen für das Zielgerät angezeigt, welcher folglich das maschinennahe System, wie zum Beispiel eine SPS, konfiguriert. Dies geschieht über eine definierte Schnittstelle, dem HMI (human machine interface). Damit das APPsist-System die richtigen Informationen anzeigen kann, werden laut Autoren mehrere Datenquellen genutzt. Neben naheliegenden Daten aus dem Zielprozess (2) werden ebenfalls Planungs- und Auftragsdaten (3) aus dem Planungssystem, sowie spezifisch vom Bediener zur Verfügung gestellte Daten (1) verarbeitet.

In [Ewe06] wurde ein Assistenzsystem für die Prozessplanung entwickelt, welches für einen Formdruck-Prozess optimierte Prozessparameter ermittelt. Hierfür wird zunächst mittels Case-Based Reasoning anhand von Erfahrungsdaten und einem Ähnlichkeitsmaß [Ewe06, S. 180ff.] ein potentiell geeigneter Parametersatz identifiziert und in Kombination mit der statistischen Versuchsplanung der Prozess abgebildet. Hierbei wird mit einem raumfüllenden Versuchsplan [Ewe06, S. 190ff.] auf die spezifischen Anforderungen des Druckprozesses eingegangen. Die Qualitätsmerkmale des Prozesses wurden so gewichtet, dass eine ausgewogene Berücksichtigung aller Qualitätsanforderungen [Ewe06, S. 211] gelang. In [WK18] wurde ein Assistenzsystem für den Rüstprozess einer **Webmaschine** entwickelt. Die Entwicklung wurde in enger Abstimmung mit den Endanwendern durchgeführt, sodass ein bedarfsgerechtes Assistenzsystem entstanden ist. Dieses beinhaltet neben Handlungsanweisungen für die Arbeitsschritte des Rüstens, ein Kommunikationsmodul, eine Visualisierung von Maschinendaten und ein Lerntool für den Anwender. Insbesondere die Handlungsanweisungen sind qualitativer Natur.

Fazit

Die oben beschriebenen Assistenzsysteme haben gemein, dass sie den Rüstprozess für einen spezifischen Produktionsprozess (Dreh- und Fräsmaschine, Rohrbiegen und Webmaschine) für den Bediener vereinfachend aufbereiten. In den letzten Fällen wird insbesondere bereits vorhandenes, qualitatives Expertenwissen über den Prozess aufbereitet. Resultierend werden Handlungsempfehlungen gegeben, welche Aufgaben als nächstes erfüllt werden müssen. Somit werden vorrangig Prozessschritte für verschiedene Zielgruppen illustriert und angenommen, dass keine weitere iterative Interaktion mit der Anlage notwendig ist. Im Fall von Störungen und Abweichungen der Anlage vom Normalverhalten ist dies in der Verantwortung des Bedieners, die qualitativen Beschreibungen in quantitative Handlungen umzusetzen. Eine explizite Unterstützung für das Finden und Optimieren der Prozessparameter wird allein in [TEGP13] vorgestellt. Aber auch hier werden anhand der Daten nur einmalig optimierte Parameter berechnet. Ein unbekanntes Verhalten der Maschine oder bei der Modellierung nicht betrachtete Störungen werden nicht berücksichtigt. Die Veröffentlichung hat jedoch aufgezeigt, dass sowohl experimentelle Daten, als auch historische Daten für das Einrichtsystem genutzt werden können und sollten. Diese Daten werden stets zu Repräsentationen des Prozesses verarbeitet. Im folgenden Abschnitt liegt der Fokus auf die Nutzung solcher datengetriebenen Modelle in der heutigen Produktion und der produktionsnahen Forschung.

2.4 Datengetriebene Modellbildung

Bereits bei der Analyse der Parameterermittlung zum Einrichten der Produktionsprozesse in Abschnitt 2.2 hat sich gezeigt, dass für die Berechnung der Prozessparameter zumindest in der Forschung in vielen Fällen ein methodisches Vorgehen gewählt wird. Häufig ist in der Literatur die Nutzung datengetriebener Verfahren zu finden, um effiziente Modelle für die Optimierung der Prozessparameter zu berechnen. Die hierfür benötigten Daten können sowohl vom realen Prozess (zum Beispiel [SN19]), als auch von Simulationsmodellen (zum Beispiel [KB16]) erfasst werden. Es kann zwischen geplanten Versuchen im Sinne der Response-Surface-Methode mittels statistischer Versuchsplanung und der Nutzung historischer Daten mittels Machine Learning unterschieden werden. Im Folgenden wird die Anwendung der beiden datengetriebenen Verfahren näher erörtert.

2.4.1 Response-Surface Methode

Das Ziel bei der Anwendung der Response-Surface Methode (RSM) ist eine Approximation des Ein-/ Ausgangsverhaltens eines Zielsystems zu berechnen, um das System besser zu verstehen, Einflüsse zu charakterisieren oder auch Optimierungen durchzuführen. Das Verfahren wird in der Regel durch die statistische Versuchsplanung (engl. *Design of Experiments (DoE)*) unterstützt, welche die effiziente Planung und Durchführung von Versuchen unter Berücksichtigung potenzieller Wechselwirkungen im ermöglicht.

Diese Unterstützung ist notwendig, weil das intuitive Verhalten der meisten Menschen bei Optimierungsproblemen zu einer suboptimalen Lösung führt: die Analyse des Einrichtens hat beispielhaft gezeigt, dass die Ermittlung optimaler Justagen in der Anwendung manuell durchgeführt werden. Das bedeutet, es wird ein „Best Guess Approach“ oder der „One Factor At A Time“-Ansatz gewählt. [Mon13] Bei letzterem variiert der Anwender stets genau eine Justagemöglichkeit, in dieser Domäne auch Faktor genannt, bis er ein zufriedenstellendes Ergebnis erlangt. Häufig existieren in technischen Systemen jedoch Wechselwirkungen zwischen den einzelnen Faktoren, die bei dieser Experimentierweise nicht berücksichtigt werden. Hier greift der „Best Guess“-Ansatz ein, bei dem durch den Menschen unter Berücksichtigung des Expertenwissens die Faktoren variiert werden. Problematisch hieran ist, dass dieses Expertenwissen bei unbekannten Systemen häufig noch nicht voll ausgeprägt ist und daher zu vielen Iterationen führen kann. Dies ist zeit- und kostenintensiv und somit schnell unwirtschaftlich. Weiterhin tendieren Menschen dazu, Sachverhalte ohne Ursache-Wirkungs-Zusammenhang zu korrelieren. Zur Lösung dieses Problems bietet die statistische Versuchsplanung ein methodisches Vorgehen an, das den ersten Schritt der RSM darstellt.

Allgemeine Vorgehensweise

Im Folgenden wird die grundlegende Vorgehensweise beschrieben, um eine Approximation des Zielprozesses mithilfe der RSM zu erhalten. Anschließend werden die wesentlichen Werkzeuge (statistische Versuchspläne und die ANOVA) näher erörtert und Anwendungen in der Wissenschaft aufgezeigt. Im ersten Schritt der Methodik werden zunächst mithilfe eines Experten-Teams mögliche Faktoren zusammengetragen und strukturiert.

Im nächsten Schritt wird die Signifikanz dieser Faktoren experimentell nachgewiesen. Da aus wirtschaftlichen Gründen die Anzahl der Versuche bei realen Anlagen begrenzt ist, wird in diesem Stadium nur eine möglichst geringe Versuchszahl genutzt. Hierfür wird häufig ein teilfaktorieller Versuchsplan genutzt, um die Vorversuche durchzuführen [MMA16]. Ein teilfaktorieller Plan deckt nur einen Teil der Faktorkombinationen ab und reduziert so die Versuchszahl. Eine genauere Erläuterung findet sich im Abschnitt zu den Versuchsplänen. Das Ziel von diesem Schritt ist, die Berechnung eines meist polynomialen Regressionsmodells erster Ordnung der Form

$$\hat{y}_k = \beta_{k,0} + \sum_{i=1}^n \beta_{k,i} x_i,$$

um die Auswirkungen der Einflüsse zu bestätigen oder auszuschließen. Hierbei ist y_k das betrachtete Qualitätsmerkmal, β die Regressionskoeffizienten und x_i sind n meist auf den Bereich ± 1 normierte Faktoren. Mit dem Ergebnis können die anschließenden Hauptversuche effizient und bedarfsgerecht durchgeführt werden.

Im nächsten Schritt beginnt die eigentliche, tiefgehende Prozessanalyse. In diesem Stadium wird ein ausführlicherer Versuchsplan genutzt, um Versuche für ein genaueres, bedarfsgerechtes Modell durchzuführen. Bei der Planung der Experimente mithilfe der statistischen Versuchsplanung (SVP) werden drei Grundprinzipien [Mon13] genutzt:

- die Randomisierung,
- die Replikation und
- die Blockbildung.

Unter Randomisierung wird verstanden, dass sowohl die Versuchsmittel als auch die Versuche selbst in zufälliger Reihenfolge gewählt werden [Mon13], um systematische Fehler aus den Versuchen zu reduzieren. In einigen Fällen ist eine komplette Randomisierung der Versuche nicht immer möglich, da zum Beispiel aus wirtschaftlichen Gründen, ein Prozessparameter nicht beliebig variiert werden kann. So ist denkbar, dass eine Temperatur in einem Ofen wenig verstellt werden sollte, da dieser eine längere Zeit benötigt, um aufzuheizen und abzukühlen. Unter Replikation wird verstanden, dass einzelne Versuche unabhängig voneinander wiederholt werden, um die Wiederholgenauigkeit zu ermitteln. Hierbei wird darauf geachtet, dass jeder Versuch unabhängig voneinander vorbereitet wird, um ebenfalls systematische Fehler zu minimieren. Die Blockbildung dient dazu, Störungen aus den Versuchsdaten zu eliminieren, so kann für einen Versuch Bandmaterial von zwei verschiedenen Coils aus unterschiedlichen Herstellungsprozessen notwendig sein. Bei der Blockbildung werden Blöcke von gleichen Versuchen gebildet, um den Einfluss solch unkontrollierbarer Faktoren zu berechnen und in der Auswertung zu berücksichtigen [SvH10]. Das Ergebnis ist ein in der Regel polynomiales Regressionsmodell zweiter Ordnung [MMA16]:

$$\hat{y}_k = \beta_{k,0} + \sum_{i=1}^n \beta_{k,i} x_i + \sum_{i=1}^n \beta_{k,ii} x_i^2 + \sum_{j=2}^n \sum_{i=1}^{j-1} \beta_{k,i,j} x_i x_j$$

Gründe für das Polynom sind unter anderem viele erfolgreiche Anwendungen und eine einfache Handhabung, um zum Beispiel die Regressionskoeffizienten zu berechnen. Dieses Modell wird anschließend für weitere Analysen und Optimierungen genutzt und „Response Surface“ genannt. Das Qualitätsmerkmal y_k des Produkts wird durch n normierte




Bild 2-15: Ein vollfaktorieller Versuchsplan in einem zweidimensionalen Parameterraum, nach [Mon13, S. 184]

Faktoren x_i beeinflusst. Diese Einflussgrößen bilden zusammen mit den zuvor definierten Systemgrenzen den Parameterraum, welcher Region of Interest (RoI, Bereich von Interesse) [MMA16] genannt wird. Dieser bildet eine Teilmenge des funktionsfähigen Bereichs (engl. *region of operability (ROO)*). Zur Berechnung des Zielmodells kann eine lineare Regression genutzt werden, um die Regressionskoeffizienten β zu berechnen. Dies ist möglich, da die Polynome zwar nichtlineare Modelle sind, die Qualitätsmerkmale aber linear von den Regressionskoeffizienten $\beta_{k,i,j}$ abhängig sind. Das Ergebnis ist ein Regressionsmodell, welches zum Beispiel für eine Optimierung genutzt wird. Um im Modell nur die signifikanten Faktoren und Faktorkombinationen als Einflüsse zu berücksichtigen, wird es in der Regel mithilfe einer Analysis of Variance (ANOVA) auf die wesentlichen Einflüsse reduziert.

Der letzte Schritt ist die Validierung des Optimierungsergebnisses. Hierfür werden keine speziellen Versuchspläne benötigt, sondern eine geringe Anzahl an Versuchen, um das identifizierte Optimum zu bestätigen. [MMA16] Es ist ersichtlich, dass die Qualität des Optimierungsergebnis abhängig ist vom gewählten Regressionsmodell und dem Versuchsplan. Aus diesem Grund existiert eine Vielzahl unterschiedlicher Versuchspläne, von denen eine Auswahl im Folgenden erörtert wird.

Versuchspläne

Versuchspläne stellen ein methodisches Vorgehen dar, um Experimente zu strukturieren und eine hohe Aussagekraft aus einer minimalen Versuchszahl zu extrahieren. Für die Versuche werden die wesentlichen Einflussfaktoren identifiziert und systematisch variiert. Die Faktoren spannen dabei einen Parameterraum auf, in dem sie variiert werden können. Dieser wird ebenfalls ROI (engl. *region of interest*) genannt. Um die Auswirkungen der einzelnen Faktorkombinationen vergleichen zu können, werden die Faktoren auf einen einheitlichen Bereich (z.B. ± 1) normiert. Die Methode stellt die Berücksichtigung der Wechselwirkungen stets in den Fokus.

Der vollfaktorielle zweistufige Versuchsplan (engl. *factorial design*) (2^n -Design) kann als grundlegender Versuchsplan angesehen werden [MMA16]. Diesen Plan (siehe Abbildung 2-15) zeichnet aus, dass in dem betrachteten Parameterraum die Ecken des Parameterraums abgeprüft werden (siehe Abbildung 2-15). Hierbei werden die Faktoren

bekannten Eckpunkten des Parameterraums zusätzlich aus Sternpunkten auf den Parameterachsen und einem Zentralpunkt. Diese zusätzlichen Versuchspunkte ermöglichen zwei zusätzliche Freiheitsgrade [Mon13]:

- den Abstand α der Sternpunkte zum Zentrum und
- die Anzahl n_c der Zentralpunktversuche.

Der Abstand α beeinflusst die Rotierbarkeit des Versuchsplans. Rotierbarkeit bedeutet, dass die Präzision, ausgedrückt in der Varianz der Prädiktionen, des Modells bei Rotation des Versuchsplans nicht beeinflusst wird [Mon13, S. 502] und geht mit einer gleichmäßigen Verteilung der Versuchspunkte einher. Diese sind durch den Anteil der Versuche im vollfaktoriellen Versuchsplan n_F bestimmt, sodass gilt [Mon13, S. 504]

$$\alpha = \left(n_f\right)^{\frac{1}{4}}.$$

Der zweite Freiheitsgrad ist die Versuchsanzahl der Zentralpunkte. Diese dienen der Einstellung einer ausgewogenen Präzision der Vorhersage über den gesamten Parameterraum. Erfahrungswerte [Mon13, S. 503] zeigen, dass eine drei- bis fünfmalige Wiederholung des Zentralversuchs gute Ergebnisse erzielt.

In diesem Abschnitt wurden Grundlagen für Versuchspläne erörtert, die ein strukturiertes und wissenschaftliches Vorgehen für die Durchführung von Versuchen bereitstellen. Neben dem voll- und teilfaktoriellen Versuchsplan wurden ebenfalls die zentral zusammengesetzten Versuchspläne kurz vorgestellt. Es gibt eine Vielzahl unterschiedlicher Versuchspläne, die individuelle Charakteristika besitzen. So existieren D-, G- oder auch I-optimale Designs (siehe [Mon13; SvH10; MMA16]), die unterschiedliche Kenngrößen der Varianz,

- Regressionskoeffizienten,
- maximale Vorhersagevarianz,
- durchschnittliche Vorhersagevarianz

minimieren. Beispielhaft bedeutet D-optimal, dass mithilfe des Versuchsplans die Varianz der Regressionskoeffizienten minimiert wird [Mon13, S. 282]. Es gibt Box-Behnken Designs [Mon13], die sich durch eine hohe Effizienz und (nahezu) Rotierbarkeit auszeichnen, dreistufige vollfaktorielle Versuchspläne oder auch gemischtstufige Versuchspläne [MMA16]. Es kann somit für die Versuchsbasis aus einem vielfältigem Repertoire geschöpft und je nach Bedarf der geeignete Plan ausgewählt werden.

Varianzanalyse

Die Varianzanalyse (ANOVA, Analysis of Variance) dient dazu, die scheinbaren Einflüsse von den signifikanten Einflüssen zu unterscheiden. So kann das resultierende Regressionsmodell auf die wesentlichen Faktoren begrenzt und eine bessere Generalisierung erreicht werden. Im Folgenden wird das Vorgehen einer Varianzanalyse für einen vollfaktoriellen Versuchsplan mit zwei Faktoren vorgestellt³. Diese Methodik ist auf komplexere Aufgabenstellungen übertragbar [Mon13, S. 206]. Grundlage für die Erläuterung ist ein

	Faktor B			
	1	2	...	b
Faktor A	1	$y_{111}, y_{112}, \dots, y_{11n}$	$y_{121}, y_{122}, \dots, y_{12n}$	$y_{1b1}, y_{1b2}, \dots, y_{1bn}$
	2	$y_{211}, y_{212}, \dots, y_{21n}$	$y_{221}, y_{222}, \dots, y_{22n}$	$y_{2b1}, y_{2b2}, \dots, y_{2bn}$
	$\vdots$	$\vdots$	$\dots$	$\vdots$
	a	$y_{a11}, y_{a12}, \dots, y_{a1n}$	$y_{a21}, y_{a22}, \dots, y_{a2n}$	$y_{ab1}, y_{ab2}, \dots, y_{abn}$

Tabelle 2-1: Struktur der vollfaktoriellen Versuchsdurchführung, nach [Mon13, S. 189]

Einflussmodell (engl. *effects model*) erster Ordnung inklusive der Wechselwirkung. Zusätzlich wurden bereits die Versuche durchgeführt.

Die durchgeführten Versuche können, wie in Tabelle 2-1 zu sehen, strukturiert werden. Die beiden Faktoren A (mit a Stufen) und B (mit b Stufen) werden gemäß des Versuchsplans im Zusammenspiel mit einer n -fachen Wiederholung pro Versuchskonfiguration getestet. Jeder Versuch y_{ijk} wird nun mit einem Modell $\hat{y}_{ijk}$ als Summe aus einzelnen Einflüssen beschrieben:

$$\hat{y}_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk} \quad (2-1)$$

Jeder Versuch setzt sich demnach aus einem allgemeinen Mittelwert μ , dem Einfluss vom Faktor A τ_i , dem Einfluss vom Faktor B β_j , der Wechselwirkung der beiden Einflüsse $(\tau\beta)_{ij}$ und einem Fehler ε zusammen. Die Einflüsse und die Wechselwirkungen sollen lediglich eine Abweichung vom Mittelwert μ beschreiben. Daher gilt [Mon13, S. 188]:

$$\sum_{i=1}^a \tau_i = 0 \mid \sum_{j=1}^b \beta_j = 0 \mid \sum_{i=1}^a (\tau\beta)_{i,j} = 0 \mid \sum_{j=1}^b (\tau\beta)_{i,j} = 0$$

Es soll nun nachgewiesen werden, dass einer der Einflüsse sich signifikant auf die Versuchsergebnisse auswirkt. Die Nullhypothesen H_0 sind daher, dass keine signifikanten Einflüsse $(\tau_i, \beta_i, \tau\beta)_{1,1}$ auf die Versuchsdaten vorhanden sind und die Alternativhypothese, dass eine Auswirkung existent ist:

$$\begin{array}{l|l|l} H_0 : \tau_1 = \dots = \tau_a = 0 & H_0 : \beta_1 = \dots = \beta_b = 0 & H_0 : (\tau\beta)_{1,1} = \dots = (\tau\beta)_{a,b} = 0 \\ H_1 : \exists \tau_i \neq 0 & H_1 : \exists \beta_j \neq 0 & H_1 : \exists (\tau\beta)_{i,j} \neq 0 \end{array} \quad (2-2)$$

Zur Berechnung der Signifikanzen wird eine sogenannte ANOVA-Tabelle (siehe Tabelle 2-2) konstruiert. Die verfolgte Idee ist, das Verhältnis der Varianz der Faktoreffekte zur Varianz der (nicht erklärbaren) Fehlereinflüsse zu bewerten. Die Tabelle wird von links nach rechts bearbeitet. Die erste Spalte listet die aus Gleichung 2-1 bekannten Einflüsse, sowie den Gesamteinfluss auf.

³eine detaillierte Ausführung findet sich in [Mon13, S. 188]

Variations- ursache	Quadrat- summe	Freiheits- grade	Abweichungs- quadrate	F_0
A (τ_i)	SS_A	$a - 1$	$MS_A = \frac{SS_A}{a-1}$	$F_0 = \frac{MS_A}{MS_E}$
B (β_i)	SS_B	$b - 1$	$MS_B = \frac{SS_B}{b-1}$	$F_0 = \frac{MS_B}{MS_E}$
AB ($\tau_i \beta_i$)	SS_{AB}	$(a-1)(b-1)$	$MS_{AB} = \frac{SS_{AB}}{(a-1)(b-1)}$	$F_0 = \frac{MS_{AB}}{MS_E}$
Fehler (ε_i)	SS_E	$ab(n-1)$	$MS_E = \frac{SS_E}{ab(n-1)}$	
Gesamt	SS_T	$abn - 1$		

Tabelle 2-2: ANOVA-Tabelle für ein zweifaktorielles Design, nach [Mon13, S. 192]

Im nächsten Schritt werden die individuellen Quadratsummen der Einflüsse berechnet. Diese lassen sich aus der Gleichung für die Gesamtquadratsumme (engl. *total sum of squares*) ableiten. Zur Erhaltung der Übersicht wird eine zusammenfassende Notation eingeführt. Hierbei entspricht

- $y_{i..}$ der Summe aller Versuche aus der Stufe i des Faktors A,
- $y_{.j.}$ der Summe aller Versuche aus der Stufe j des Faktors B,
- $y_{..k}$ der Summe aller Versuche aus der Versuchskonfiguration ij und
- $y_{...}$ der Summe aller Versuche.

Die Gesamtquadratsumme aus der letzten Zeile der ANOVA-Tabelle

$$SS_T = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{...})^2$$

beschreibt die quadratische Abweichung vom Gesamtmittelwert und enthält folglich alle Quadratsummen, sowohl die der Einflüsse A und B als auch die der Wechselwirkung und des Fehlers. Das bedeutet, dass diese Komponenten ebenfalls in dieser Summe vorhanden sind: dies wird genutzt, um die Berechnung der weiteren Quadratsummen herzuleiten. Durch Erweiterung der Gleichung mit den Mittelwerten der Summen der einzelnen Einflüsse und anschließender Vereinfachung der Summen, kann sie auf die folgende Form

gebracht werden:

$$\begin{aligned}
 SS_T &= \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{...})^2 = SS_A + SS_B + SS_{AB} + SS_E \\
 &= \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n [(\bar{y}_{i..} - \bar{y}_{...}) + (\bar{y}_{.j.} - \bar{y}_{...}) + (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...}) + (y_{ijk} - \bar{y}_{ij.})]^2 \\
 &\quad \vdots \\
 &= \underbrace{bn \sum_{i=1}^a (\bar{y}_{i..} - \bar{y}_{...})^2}_{SS_A} + \underbrace{an \sum_{j=1}^b (\bar{y}_{.j.} - \bar{y}_{...})^2}_{SS_B} \\
 &\quad + \underbrace{n \sum_{i=1}^a \sum_{j=1}^b (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})^2}_{SS_{AB}} + \underbrace{\sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{ij.})^2}_{SS_E}
 \end{aligned}$$

Die Mischterme der quadratischen Gleichung verschwinden, da sie in Summe null ergeben [Mon13, S. 190]. Die verschiedenen Quadratsummen werden zusammen mit den Freiheitsgraden in Spalte drei der ANOVA-Tabelle genutzt, um die mittleren Abweichungsquadrate (MS: engl. *mean square*) zu berechnen. Die mittleren Abweichungsquadrate der Einflüsse werden mit dem mittleren Abweichungsquadrat des Fehlers normiert, um den Wert F_0 zur Überprüfung der Nullhypothese zu berechnen. Die Nullhypothese aus Gleichung 2-2 wird akzeptiert, wenn [Mon13, S. 58]

$$F_0 < F_{\alpha, u, v}$$

ist. Dies bedeutet folglich, dass bei dem Einfluss kein signifikanter Effekt nachgewiesen werden konnte. In dieser Gleichung ist α das gewünschte Signifikanzniveau, u der Freiheitsgrad des Zählers und v der Freiheitsgrad des Nenners bei der Berechnung von F_0 . Die Funktion F wird über das Integral der Wahrscheinlichkeitsdichtefunktion $h(x)$ [Mon13, S. 35] berechnet, welche die Gamma-Funktion beinhaltet.

$$\begin{aligned}
 h(x) &= \frac{\Gamma\left(\frac{u+v}{2}\right) \left(\frac{u}{v}\right)^{u/2} x^{(u/2)-1}}{\Gamma\left(\frac{u}{2}\right) \Gamma\left(\frac{v}{2}\right) \left[\frac{u}{v} x + 1\right]^{(u+v)/2}} & \text{mit } 0 < x < \infty \\
 \Gamma(z) &= \int_0^\infty t^{z-1} e^{-t} dt & \text{mit } z \in \mathbb{C}
 \end{aligned}$$

Diese Verteilung heißt Fisher-Verteilung oder auch kurz F-Verteilung. In der Praxis ist diese Funktion in Tabellenwerken oder auch bereits als Funktion in den Programmen abgelegt. Mit diesem Bewertungskriterium können demnach sowohl die Haupteinflüsse, als auch die Wechselwirkungen analysiert werden. Das Resultat ist eine Berücksichtigung oder ein Ausschluss des Einflusses im Regressionsmodell, welches folglich eine generellere Approximation bietet.

In diesem Abschnitt wurde ein Überblick über die Response-Surface Methode, inklusive der statistischen Versuchsplanung und der Berechnung signifikanter Regressionsmodelle




Bild 2-17: Prinzip des „Face-centered“ zentralzusammengesetzten Versuchsplans, nach [SvH10, S. 40]

gegeben. Hierfür wurde das Grundkonzept, eine Einführung in die Versuchspläne und in die Varianzanalyse gegeben. Aufgrund der Vielschichtigkeit der Thematik sei an dieser Stelle für einen tieferen Einblick auf die zitierte Literatur verwiesen. Es wurde bereits bei der Analyse der Parameteridentifikation zum Einrichten von Produktionsprozessen (siehe Abschnitt 2.2) angedeutet, dass die statistische Versuchsplanung ein wichtiges Werkzeug in diesem Bereich ist. Im Folgenden werden die Anwendungen vom Abschnitt 2.2 im Kontext der statistischen Versuchsplanung näher erläutert.

Anwendung der Response-Surface Methode

Für die Anwendung der Parameteroptimierung für das **Tieflochbohren** [AA13] wurden zunächst die bedeutsamen Prozessparameter mithilfe von Vorversuchen identifiziert. Wie bereits beschrieben sind dies

- Drehgeschwindigkeit,
- Vorschub und
- inkrementelle Bohrtiefe.

Anschließend wurde ein zentral zusammengesetzter Versuchsplan entwickelt. Um die Parametergrenzen nicht zu verletzen, wurde ein „face-centered Design“ genutzt (siehe Abbildung 2-17). Hierbei sind die Sternpunkte auf Höhe der Eckpunkte im Parameterraum angeordnet: durch die Anordnung vermischen sich jedoch die quadratischen Effekte [SvH10, S. 38], welche sich daher nicht mehr voneinander trennen lassen. Da verschiedene Qualitätsmerkmale berücksichtigt werden mussten, aber eine schnelle Optimierung in der Veröffentlichung im Vordergrund stand, wurden die Qualitätsmerkmale in der Qualitätsfunktion [AA13]

$$J(\mathbf{y}) = \sqrt[n]{\prod_{i=1}^n y_i}$$

zusammengefasst. Das Qualitätskriterium J wird hier aus einem geometrischen Mittelwert der Einzelmerkmale y_i berechnet. Mithilfe der so geplanten 20 Versuche wurde ein quadratisches Modell berechnet und anschließend mithilfe der ANOVA die signifikanten

Einflüsse ausgewählt. Dieses Modell wurde im Anschluss daran zur Parameteridentifikation der optimalen Prozessparameter genutzt und die Ergebnisse validiert werden.

Im Falle des **inkrementellen Blechumformens** [AH15] wurden fünf Einflussfaktoren

- Blechdicke,
- Werkzeugdurchmesser,
- Anstellwinkel,
- Zustellung und
- Fließspannung

identifiziert und als Qualitätskriterium die resultierende Kraft aus den drei kartesischen Kräften genutzt. Das Ziel dieser Optimierung ist die Einstellung optimaler Justagen mit einer minimal notwendigen Kraft. Für die Versuche wurde ein Pyramidenstumpf als zu fertigende Zielgeometrie genutzt. Zunächst wurden Vorversuche durchgeführt, um die Spannweite des Parameterraums zu identifizieren. Anschließend wurde ebenfalls ein „face-centered“ zentral zusammengesetzter Versuchsplan zur Strukturierung der Versuche genutzt und insgesamt 47 Versuchskonfigurationen mit jeweils 5 Wiederholungen durchgeführt. Im Anschluss wurde eine Regressionsanalyse mit einem quadratischen Modell berechnet und die signifikanten Parameter mit einem Signifikanzniveau von 95% mithilfe der Varianzanalyse ermittelt. Die so berechneten Kraftmodelle wurden abschließend für eine exemplarische Parameteroptimierung genutzt.

Auch bei der Optimierung des **Kriechumformprozesses** [KAS⁺16] wurde die Response-Surface Methode inklusive der statistischen Versuchsplanung als Methodik eingesetzt. In diesem Fall wurden zwei Parameter,

- die Haltezeit und
- die Umformtemperatur,

identifiziert. Das Qualitätsmerkmal und auch das alleinige Optimierungsziel war die Rückfederung des Materials. Es wurden für die Haltezeit fünf Stufen und für die Umformtemperatur zwei Stufen gewählt. Mittels eines D-optimalen Designs⁴ wurden 16 Versuche geplant. Anschließend wurde ein quadratischer Ansatz in der Regressionsanalyse genutzt, um das Modell für die Rückfederung zu berechnen. Eine anschließende Varianzanalyse bestätigte die Signifikanz der vorhandenen Parameter des Modells mit einem gewählten Signifikanzniveau von 99%. Anschließend wurde die Vorhersagegenauigkeit des Modells mit zusätzlichen Versuchen validiert und genutzt, um gute mechanische Eigenschaften der Produkte mithilfe einer händischen Optimierung einzustellen.

In [Nad06] wurde ein Drückprozess optimiert, indem über ein Case-Based Reasoning der Parameterraum für die drei identifizierten Prozessgrößen abgeschätzt und anschließend automatisiert ein Versuchsplan für diesen Parameterraum berechnet wurde. Folgend wurden die Versuche durchgeführt und Gauß-Prozess-Modelle für die einzelnen Qualitätsmerkmale berechnet. Über eine Gewichtung der Qualitätsmerkmale zueinander wurde abschließend das globale Optimum für die Prozessparameter gefunden.

Dies waren vier Beispiele für die Anwendung der RSM im Bereich der Produktion. In der Literatur findet sich eine Vielzahl an Veröffentlichungen, die diese Methode nutzen,

⁴für weitere Informationen siehe [Mon13, S. 282]

um Systeme zu analysieren und optimieren. Weitere Beispiele sind im Bereich der Optimierung der Design-Parameter für Solarthermieranlagen [QSAT19], der Optimierung eines Schweißprozesses [AA19], der Vorhersage von Werkzeugschwingungen beim Drehen [KS18] oder auch der Optimierung des Fräsprozesses für faserverstärkte Kunststoffe [KAS17].

Fazit

In diesem Abschnitt wurde die Response-Surface Methode inklusive der statistischen Versuchsplanung vorgestellt. Zunächst wurden das allgemeine Vorgehen und grundlegende Konzepte erläutert und anschließend wichtige Werkzeuge, wie Versuchspläne und die Varianzanalyse skizziert. Abschließend wurden anhand ausgewählter Beispiele aus der Literatur verwandte Anwendungen aufgezeigt.

Die RSM und die statistische Versuchsplanung ist ein wichtiges Instrument, wenn mit einer geringen Versuchszahl eine statistisch abgesicherte Aussage getätigt werden soll. Es hat sich gezeigt, dass die Konzepte in der Literatur bereits vielfältige Anwendung gefunden haben und das Vorgehen in der Wissenschaft etabliert ist. So wurden bereits Parameter für eine Vielzahl unterschiedlicher Prozesse mithilfe dieser Methodik gefunden. Dem gegenüber steht, dass die Anwendung häufig genau einmal stattfindet, da von einem zeitinvarianten Prozessverhalten ausgegangen wird. Sobald sich der Prozess ändert, muss das Vorgehen in der Regel neu appliziert werden. Sollten sich nicht-messbare Einflüsse auf den Prozess auswirken, werden suboptimale Parameter mithilfe der Optimierungsstrategien ausgewählt.

Neben gezielt geplanten Versuchen gewinnen die großen Sammlungen von Produktionsdaten zunehmend an Bedeutung. Aufgrund der Industrie 4.0 Strategie werden immer mehr Maschinen vernetzt und Produktionsdaten durch eine steigende Sensorzahl erfasst. Häufig werden diese Daten in Cloud-Speichern abgelegt und können hinsichtlich unterschiedlicher Fragestellungen ausgewertet werden. Die so vorliegenden Daten sind vom Konzept konträr zur statistischen Versuchsplanung, gehören jedoch auch zur datengetriebenen Modellbildung und geben wichtige Einblicke in die Produktion.

2.4.2 Machine Learning Verfahren

In diesem Abschnitt wird ein zusammenfassender Überblick über die Thematik des maschinellen Lernens gegeben. Analog zum vorherigen Abschnitt werden zunächst die Basiskonzepte für die Anwendung maschineller Lernverfahren erörtert. In diesem Zuge werden die wesentlichen Begriffe definiert. Der Abschnitt schließt mit einer Auswahl kontextbezogener Anwendungen und einer Bewertung ab.

Grundlagen des maschinellen Lernens

Das maschinelle Lernen wird als Untergruppe der künstlichen Intelligenz verstanden, welche wiederum Teilgebiet der Informatik ist und sich mit intelligenten Algorithmen auseinandersetzt. Intelligent bedeutet in diesem Zusammenhang, der Versuch den Menschen




Bild 2-18: Cross-Industry Standard Process for Data Mining, nach [HWSI19]

in seiner Fähigkeit der Wissensgenerierung und Anwendung zu imitieren. Für dieses Vorhaben spielen insbesondere Approximationsmethoden, wie die Algorithmen des Machine Learning (ML), eine bedeutende Rolle: sie werden häufig als Synonym für eine künstliche Intelligenz verwendet. Bereits 1959 hat Arthur Samuel diesen Bereich definiert:

“Maschinelles Lernen: ein Forschungsbereich, der Computer zum Lernen befähigt, ohne dass sie explizit programmiert werden.“⁵

Mittlerweile existieren zahlreiche weitere Definitionen mit individuellen Ausprägungen. Zur Anwendung der ML-Verfahren in der Praxis existieren eine Vielzahl unterschiedlicher Vorgehensmodelle ([NE09, S. 46], [LM08, S. 148]). Eines der bekanntesten ist der Cross-Industry Standard Process for Data Mining (CRISP-DM) (siehe Abbildung 2-18). Das Vorgehensmodell besteht aus sechs Teilschritten und beschreibt dabei einen iterativen Vorgang, um von den Daten zu einem bereitgestellten System zu gelangen. Hierbei ist es branchenübergreifend anwendbar, demzufolge auch im Produktionsbereich, an dem das Vorgehensmodell im Folgenden erläutert wird. Im ersten Schritt, dem *Business Understanding*, werden zunächst die Unternehmensziele untersucht und die relevanten Entitäten ermittelt. So kann ein Ziel sein, die Maschinen prädiktiv zu warten, um ungeplante Instandhaltungseinsätze zu reduzieren und eine damit verbundene höhere Maschinenverfügbarkeit zu erreichen. Hierfür werden dann ebenfalls die zu berücksichtigenden Maschinen ermittelt.

Weitere mögliche Ziele sind in Abbildung 2-19 abgebildet. Hier wird zwischen einer de-

⁵aus dem Englischen: “Machine Learning: Field of study that gives computers the ability to learn without being explicitly programmed.”

tungen, um dieses Wissen zu generalisieren und nutzbar zu machen. Die Beobachtungen bestehen dabei aus Input-Daten und Output-Daten (häufig Label genannt). Diese Daten können hinsichtlich unterschiedlicher Lernaufgaben (siehe Abbildung 2-20) genutzt werden, sodass zwischen der Klassifikation, der Regression und dem Clustering unterschieden wird [DLV⁺18].




Bild 2-20: Lernaufgaben maschineller Lernverfahren

Bei einer Klassifikation wird anhand der Input-Daten die Zugehörigkeit zu einer Klasse definiert. Der Modellausgang ist daher diskreter Natur und in vielen Fällen sogar binär. Im Kontext dieser Arbeit könnte eine Klasse die Herstellung funktionsfähiger Produkte, das Erreichen einer definierten Prozessfähigkeit oder ähnliches sein. Die Regression erweitert dieses Konzept hinsichtlich eines kontinuierlichen Modellausgangs auf den die Eingangsvariablen abgebildet werden. Das Modell wird dann für die Prädiktion des Systemverhaltens für neue Justagekonfigurationen genutzt. Die im vorherigen Abschnitt angesprochene lineare Regression stellt einen möglichen Algorithmus dieser Lernklasse dar, mit welcher die Justagen auf die Qualitätsmerkmale abgebildet werden könnten. Die letzte Lernart bildet das Clustering, welches ähnliche Datensätze gruppiert und diese gruppierten Daten zurückgibt. Dieser Ansatz ist insbesondere wichtig, wenn ein Datensatz ohne definiertem Ausgang (Label) vorhanden ist und bezüglich signifikanter Unterschiede analysiert werden muss. Für die drei Anwendungen gibt es unterschiedliche Lernstile, die je nach System und Datenlage genutzt werden können. Diese lassen sich in überwachtes (engl. *supervised learning*), unüberwachtes (engl. *unsupervised learning*) und bestärkendes (engl. *reinforcement learning*) Lernen unterteilen [DLV⁺18]. Für die Klassifikation und Regression von Daten wird ein überwachtes Lernen genutzt.

Das Prinzip des überwachten Lernens ist in Abbildung 2-21 zu sehen. Die Grundlage für eine solche Lernart sind Rohdaten, welche von dem Zielsystem aufgenommen wurden oder ggf. auch von einer komplexeren Simulation generiert wurden. Die Daten werden mit den Output-Daten in Verbindung gebracht, das heißt zu den Input-Daten werden die zugehörigen Label zugeordnet. Dies geschieht über eine externe Instanz, dem Supervisor, der die namensgebende überwachende Funktion einnimmt und sowohl eine Person als auch ein automatisiertes System sein kann. Der vervollständigte Datensatz wird nun in Trainings- und Validierungsdaten aufgeteilt: die Trainingsdaten werden dem ML-Algorithmus übergeben und die Hyperparameter für das Verfahren konfiguriert. Das Ergebnis des Algorithmus ist ein ML-Modell, welches abschließend gegen die Validierungs-




Bild 2-21: Prinzip des überwachten Lernens




Bild 2-22: Prinzip des unüberwachten Lernens

daten getestet, also validiert wird. Anhand der Vorhersagegenauigkeit kann die Potenz des Algorithmus abgeschätzt werden. Beispielhafte bekannte Algorithmen sind [DLV⁺18]

- Lineare Regression,
- Support Vector Machines,
- Neuronale Netze,
- Logistische Regression, uvm.

Im Gegensatz zum überwachten Lernen wird das unüberwachte Lernen zum Clustern (Separieren) von Daten genutzt: das Prinzip ist in Abbildung 2-22 dargestellt. In diesem Lernstil existiert keine externe Instanz, die ein Labeling der Daten bereitstellt. Das Ziel ist daher, die Daten auf Ähnlichkeit zu untersuchen und geclusterte Daten auszugeben oder die Dimension der Eingänge zu reduzieren. Hier wird der Anwender dabei unterstützt eine Struktur oder Aggregationsmöglichkeit in den Daten festzustellen und diese für weitere Schritte zu nutzen. Der bekannteste Algorithmen ist K-Means [DLV⁺18]. Das bestärkende Lernen (siehe Abbildung 2-23) findet in Interaktion mit einem Zielsystem statt, welches ebenfalls ein Simulationsmodell sein kann. Hier führt der Agent eine Aktion an einem Zielsystem aus und bekommt die Zustände des Systems, als auch eine Zielfunktion (häufig Belohnung genannt) als Rückgabe. So kann der Agent durch Variation der Aktionen die Belohnungen maximieren und eine langfristige Optimierungsstrategie entwickeln. Ein Anwendungsfall ist die Robotik, in der ideale Greifbewegungen für unsortierte Objekte gelernt werden. Ein Beispielalgorithmus ist das Q-Lernen [DLV⁺18].




Bild 2-23: Prinzip des bestärkenden Lernens

Anwendungen des maschinellen Lernens

Im folgenden Abschnitt werden kontextnahe Anwendungen aus der Literatur vorgestellt, um einen Überblick über den aktuellen Stand der Wissenschaft zu geben. Die Beispiele werden hinsichtlich ihrer Zielanwendung, also

- einer Predictive Maintenance und
- einer Prozessparameteroptimierung,

strukturiert.

Ein häufiger Anwendungsfall ist die Prädiktion des Verschleißes, der mithilfe physikalischer Modelle in der Regel nur schwer oder mit hohem Aufwand abgebildet werden kann. In [BLFS16] wurde der **Verschleiß von Gewindebohrern** in der Stahlverarbeitung mithilfe von Regressionsalgorithmen des ML abgebildet. Für die Datengrundlage wurden verschiedene Gewindebohrer aus der Produktion zyklisch während ihrer Nutzung vermessen. Der Verschleiß wurde anhand der geometrischen Merkmale der Gewindebohrer bestimmt und Umgebungseinflüsse, wie die Schmierung, variiert. Die Erfassung der geometrischen Merkmale erfolgte dabei optisch. Für die Modellierung wurden drei Einflussgrößen (der Bohrertyp, der Nocken des Gewindebohrers und die Anzahl der gefertigten Gewinde) und drei Qualitätsgrößen in Form von geometrischen Längen identifiziert. Um ein adäquates Modell zu finden, wurden vier verschiedene Regressionsalgorithmen

- Ensemble-Trees,
- Neuronale Netze,
- Support Vector Machines Regression und
- k-Nearest Neighbors

miteinander verglichen. Es hat sich gezeigt, dass die Ensemble-Trees die Daten gut approximieren. Als Bewertungskriterium wurde das Fehlerquadrat der Testdaten herangezogen.

Die Entwicklung eines Modells für die Vorhersage des Verschleißes einer Federwindemaschine ist Fokus der Arbeit in [SHPN18]. Als Einflussgrößen wurden Maschinenparameter, Qualitätsmerkmale der Produkte, Prozesskräfte, Temperaturen und weitere identifiziert und aufgenommen. Als Zielgrößen wurden die Verschleißzustände verschiedener Maschinenkomponenten, wie das Winde- oder auch Schneidwerkzeug identifiziert. Mithilfe der Maschinenbediener wurden die aufgenommenen Daten bezüglich des momentanen Verschleißes unterschiedlichen Verschleißzuständen manuell zugeordnet, um




Bild 2-24: Werkzeuglebenszeit als Funktion der Schnittgeschwindigkeit, nach [Kar19]

ein überwachtes Lernen zu ermöglichen. Für die Klassifikation der Verschleißzustände wurde eine Kreuzvalidierung (siehe zum Beispiel [Alb09, S. 428]) mit verschiedenen Algorithmen durchgeführt:

- k-Nearest Neighbors,
- Support Vector Machines,
- Decision-Trees,
- Random Forests und
- Neuronalen Netzen.

So kann laut den Autoren in einer späteren Umsetzung der Mitarbeiter mithilfe des entwickelten Systems die Produktivität der Anlage optimieren. Die Veröffentlichung beschreibt demnach einen ersten Schritt zum Aufbau einer Infrastruktur für solche datengetriebenen Verfahren und zeigt, dass die Verfahren zwar etabliert sind, jedoch noch nicht durchgängig in der Produktion Anwendung finden.

Die Prädiktion der verbleibenden **Werkzeuglebensdauer einer spanenden Bearbeitung** wurde in [Kar19] fokussiert. In der Veröffentlichung wurden mithilfe eines analytischen Modells für die verbleibende Lebenszeit eines Werkzeugs synthetisch Daten erzeugt. Dieses Modell (siehe Abbildung 2-24) bildet die Lebenszeit eines Werkzeugs bei verschiedenen Schnittgeschwindigkeiten (in *sfm*: Surface feet per minute) ab. Um die systembedingte Varianz der Werkzeugausfälle zu simulieren, wurde das Modell mit einer Normalverteilung überlagert. Für die Generierung der Daten wurde mit einer Gleichverteilung zufällig eine Schnittgeschwindigkeit ausgewählt. Diese wurde mithilfe des normalverteilten Modells in eine verbleibende Lebenszeit des aktuellen Werkzeugs umgerechnet und mit dem Grenzwert verglichen. Dadurch wurden synthetisch Daten für ausgefallene Werkzeuge (bei Überschreitung des Grenzwerts) erstellt. Es wurden eine logistische Regression und Support Vector Machines genutzt, um Modelle zu berechnen. Letzterer Algorithmus zeigt laut Autor ein sehr gutes Approximationsverhalten für die synthetischen Daten und ist auch in wirtschaftlich getriebenen Bereichen, wie einer Produktionsumgebung, effizient anwendbar.

Neben der Vorhersage des Verschleißes existieren ebenfalls vielfältige Applikationen zur




Bild 2-25: Prinzip des Vorgehens zur Optimierung des Fräsprozesses, nach [SFMW18]

Modellierung des Zusammenhangs zwischen Einflussgrößen und dem Ausgangsverhalten, um das Prozessverhalten zu optimieren. So wurde in [KHRG15] ebenfalls **inkrementelles Blechumformen** (engl. *single-point incremental forming*) modelliert und optimiert. Hierfür wurden fünf Faktoren identifiziert:

- Werkzeugdurchmesser,
- Inkrementtiefe,
- Wandwinkel,
- Vorschubgeschwindigkeit und
- Schmiermittel.

Diese Einflussfaktoren wurden in einem statistischen Versuchsplan, einem Box-Behnken-Design, mit 46 Konfigurationen variiert. Als Zielmerkmale wurden die mittlere Oberflächenrauigkeit R_a und die maximale Rautiefe R_z betrachtet. Es wurden drei datengetriebene Verfahren

- Neuronale Netze,
- Support Vector Machines Regression und
- Symbolische Regression

evaluiert und die Signifikanz der Modelle mittels statistischer Tests nachgewiesen. Anschließend wurde ein evolutionärer Optimierer genutzt, um ideale Prozessparameter zu ermitteln. Zur Validierung wurden die Experimente mit den optimierten Parametern durchgeführt und eine sehr gute Übereinstimmung mit den prädizierten Werten beobachtet.

In [SFMW18] wurde ein **Fräsprozess** optimiert, indem die Prozessstabilität mittels datengetriebener Verfahren prädiziert wurde. Als Grundlage für die benötigten Daten wurde ein geometrisch, physikalisches Modell genutzt, welches in der Berechnung allerdings deutlich rechenintensiver ist als die üblichen ML-Modelle. Neben anderen Parametern wurde ein signifikanter Einfluss der Spindelgeschwindigkeit auf die Stabilität als Qualitätsmerkmal identifiziert und ein aktiver Lernansatz implementiert. Dieser verbessert

mithilfe einer eigens entwickelten Zielfunktion den genutzten Trainingsdatensatz iterativ weiter bis ein Abbruchkriterium erfüllt ist. Basierend auf dem so zusammengestellten Datensatz werden dann die ML-Verfahren trainiert. In der Veröffentlichung wurden speziell neuronale Netze genutzt, um die Daten zu approximieren. Mithilfe des Ansatzes konnte die Stabilität anhand der Prozessparameter hinreichend genau abgebildet werden und wird perspektivisch in einem Assistenzsystem integriert, welches die Prozessstabilität sicherstellen soll.

Als letztes Beispiel in diesem Kontext dient die Arbeit von [GBCG11], welche sich mit der Vorhersage der **Rückfederung beim Blechbiegen** beschäftigt. Das hier betrachtete Biegen eines Aluminiumblechs wird von einem Laser unterstützt, der das Material partiell erwärmt. Die Erwärmung dient einer erhöhten Umformbarkeit und einer temporär reduzierten Festigkeit des Materials. Letzteres reduziert die Prozesskräfte und schont dabei die Werkzeuge, sodass diese länger genutzt werden können. Für den Zielprozess wurden fünf Faktoren als signifikante Einflüsse identifiziert:

- die Durchbiegung nach dem Vorumformen,
- die Laserleistung,
- die Lasergeschwindigkeit,
- die Anzahl der Überfahrten und
- der Quotient aus Lichtpunktfäche und dem Abstand des Lasers.

Diese Faktoren wurden mithilfe eines vollfaktoriellen gemischtstufigen Versuchsplans variiert und die Experimente durchgeführt. Mit dieser Datengrundlage wurden zwei verschieden aufgebaute neuronale Netze trainiert, eine lineare Regression durchgeführt, sowie die entstandenen Modelle analysiert. Als Fazit wurde festgehalten, dass die neuronalen Netze das Rückfederverhalten sehr gut abbilden - auch die lineare Regression mit einem Regressionsmodell erster Ordnung hat sehr gute Ergebnisse gezeigt. Als Ausblick wurde in der Veröffentlichung die Integration der Modelle in ein Assistenzsystem gegeben, welches dem Bediener die Rückfederung einfacher Geometrien aufzeigt.

Die aufgeführten Beispiele sind Indikatoren, dass ML-Verfahren fortschreitend in der Produktion eingesetzt werden: jede Anwendung erfordert separaten Entwicklungsaufwand. Insbesondere im letzten Beispiel hat sich gezeigt, dass die klassischen Verfahren, wie die statistische Versuchsplanung, ebenfalls mit den ML-Verfahren in Zusammenwirken genutzt werden.

Kombinierte Anwendung DoE und ML

Neben der separaten Anwendung der statistischen Versuchsplanung oder auch der maschinellen Lernverfahren existieren in der Forschung ebenfalls Anwendungen, die sich die Vorteile beider Methoden zu nutze machen möchten. In diesem Abschnitt werden einige vorgestellt, die bezüglich der Methodik zur Kombination der Verfahren einen unterschiedlichen Fokus legen.

So wurde in [KS15] die **Oberflächengüte eines Fräsprozesses** untersucht. Hierbei wurde eine Kombination eines vollfaktoriellen Versuchsplans mit vier Faktoren untersucht. So wurden die Parameter

- Schnittgeschwindigkeit,
- -vorschub und
- -tiefe sowie
- Werkzeugverschleiß

variiert und die resultierende Oberflächenrauigkeit R_a gemessen. Zur Approximation wurde ein neuronales Netz mit einem Hidden Layer trainiert und mithilfe eines evolutionären Optimierers die idealen Parameter bezüglich der Oberflächengüte ermittelt. Zusammenfassend wurde die statistische Versuchsplanung erfolgreich genutzt, um mit einer geringen Versuchszahl ein neuronales Netz zur Approximation der Daten zu trainieren und so eine Alternative zur klassischen linearen Regression vorgestellt.

Ein ähnliches Vorgehen ist in [KkKB14] zu finden. In dieser Veröffentlichung wurde ein **Bohrprozess** mit einer Kombination aus statistischer Versuchsplanung und maschineller Lernverfahren optimiert. So wurden Experimente basierend auf dem Box-Behnken-Design durchgeführt. Es wurden neben

- dem Bohrdurchmesser,
- die Dreh- und Vorgeswindigkeiten

variiert und multiple Qualitätsmerkmale evaluiert. Neben der Oberflächenrauigkeit wurden die Bearbeitungszeit, als auch die Rundheit des Lochs und das notwendige Drehmoment berücksichtigt. Nach der Approximation der Daten mit einem neuronalen Netz wurden wie in der Quelle zuvor zwei verschiedene Optimierer bezüglich ihrer Eignung für die verschiedenen Qualitätsmerkmale untersucht: ein evolutionärer Algorithmus und zusätzlich ein Particle Swarm Optimierer. Diese Methodik, also die Kombination aus statistischer Versuchsplanung und neuronalen Netze wird in weiteren Veröffentlichungen genutzt, zum Beispiel in [BKTW14].

Neben der Nutzung der statistischen Versuchsplanung zur effizienten Datengenerierung für das Training der Modelle wird diese ebenfalls zur Optimierung der Hyperparameter der ML-Verfahren eingesetzt. Dies entspricht somit einer weiteren Kombinationsmöglichkeit der beiden Verfahren. So wird in [LHRM18] ein Verfahren vorgeschlagen, um die Hyperparameter eines beliebigen ML-Algorithmus zu optimieren. Nach der Auswahl des ML-Algorithmus wird das Qualitätsmerkmal bestimmt und die mutmaßlich relevanten Hyperparameter (hier als Optimierungsparameter genutzt) identifiziert. Es wird vorgeschlagen, wie in der statistischen Versuchsplanung üblich, „Vorversuche“ durchzuführen und so die signifikanten Hyperparameter zu ermitteln. Anschließend wird ein vorläufiges Optimum, demnach ein geringer quadratischer Fehler, mit einem Regressionsmodell erster Ordnung ermittelt und dieses im Anschluss mit einem weiteren Versuchsplan (zum Beispiel einem Central Composite Design oder einem Box-Behnken-Design) für ein Regressionsmodell zweiter Ordnung präzisiert. Der letzte Schritt wird solange durchgeführt bis sich das so ermittelte Optimum nicht mehr signifikant ändert.

Eine Variante dieses Verfahrens wurde in der Veröffentlichung [PAB⁺16] anhand des Beispiels der **Oberflächenrauigkeitsprädiktion** vorgestellt. In dieser Veröffentlichung wurden die Hyperparameter eines neuronalen Netzes, also zum Beispiel die Anzahl der Neuronen in zwei Hidden Layern, die Zahl der Epochen für unterschiedliche Lernphasen oder auch die Lernrate mithilfe der statistischen Versuchsplanung optimiert. Anhand des

Beispiels konnten die initial trainierten Modelle erheblich verbessert werden. Zu einer ähnlichen Schlussfolgerung kommen die Autoren aus [SVGd10], die ebenfalls die Hyperparameter eines Multi-Layer-Perceptrons mithilfe der statistischen Versuchsplanung optimieren.

Fazit

In diesem Abschnitt wurden die Grundlagen des ML dargestellt. Hierzu wurde zunächst der Begriff des maschinellen Lernens definiert und ein Vorgehensmodell, der CRISP-DM, eingeführt. Anschließend wurde ein Überblick über Lernaufgaben, also Klassifikations-, Regressions- oder Clustering-Aufgaben gegeben. Darauf aufbauend wurden die Funktionsweisen des überwachten, unüberwachten und bestärkenden Lernens erörtert. Der Abschnitt schloss mit Beispielanwendungen des ML und der Kombination des ML mit der statistischen Versuchsplanung ab.

Es wird festgehalten, dass die Anwendung von datengetriebenen Verfahren durch etablierte Vorgehensmodelle, namentlich die RSM und der CRISP-DM, bereits hinreichend gut strukturiert werden können. Weiterhin haben sich diese Vorgehensweisen seit einigen Jahren zur Modellierung von Produktionsprozessen etabliert: es existieren vielfältige Anwendungen, die sich mit der Approximation solcher Prozesse beschäftigen. Trotzdem zeigt sich, dass weder die RSM noch die ML-Verfahren durchgängig in der Produktion genutzt werden. Häufig werden einmalige Lösungen geschaffen oder die Methoden gar nicht eingesetzt und auf die menschliche Intuition vertraut. Aber auch in dieser Domäne werden nicht messbare Störgrößen nicht berücksichtigt und es fehlt auch hier die Perspektive für den wiederkehrenden Einrichtungprozess.

2.5 Zusammenfassung und Fazit

Dieses Kapitel hat den Stand der Technik für die vorliegende Arbeit strukturiert und erörtert. Zunächst wurde in Abschnitt 2.1, Kategorisierung von Produktionsverfahren, ein Überblick über Produktionsverfahren und deren Einteilung nach DIN 8580 gegeben. Es wurde die Vielzahl unterschiedlicher Produktionsverfahren gezeigt, welche in der Regel tiefgreifendes Prozessverständnis benötigen, um qualitativ hochwertige Produkte innerhalb eines Produktionsprozesses herstellen zu können. Allen Prozessen ist gemein, dass sie individuelle Justagemöglichkeiten in Form von Prozessparametern, Maschineneinstellungen oder auch Umgebungsbedingungen besitzen und üblicherweise von Störgrößen beeinflusst werden. Aufgrund der immer höheren Qualitätsanforderungen und somit komplexeren Prozessen gibt es einen Trend zu autonomen Produktionsprozessen, um den Menschen bei der Produktion der Güter zu entlasten. Hierzu wurden sechs Automatisierungsstufen, analog zu den Stufen des autonomen Fahrens, vorgestellt, die eine Klassifikation der Produktionsprozesse ermöglichen. Heutige Produktionssysteme sind in der Regel bis zur dritten Stufe einzuordnen, also mit maximal einer erweiterten Automatisierung. Resultierend sind auch heute noch viele der Tätigkeiten in der Produktion manueller Natur.

Eine wesentliche Tätigkeit in der Produktion ist das Umrüsten der Maschinen zwischen zwei unterschiedlichen Produkten. Diese Zeit nimmt ungefähr 25% der Maschinenver-




Bild 2-26: Anteil der Einrichtzeit an der Maschinennutzung

fügbarekeit ein (siehe Abbildung 2-26). Durch den Trend zu geringen Lagerbeständen (um Kosten zu sparen und weniger Kapital zu binden) bei gleichzeitig kurzen Lieferzeiten, werden immer kleinere Lose gefertigt. Als Resultat wird häufiger gerüstet, welches ungefähr, neben anderen Tätigkeiten, aus 50% Einrichtzeit [SRH93, Seite 231ff] besteht. In dieser wird die Produktqualität des Folgeprodukts sichergestellt. Während dieser Tätigkeit werden die Justagemöglichkeiten, in der Regel von einem Maschinenbediener, solange variiert und angepasst, bis eine zufriedenstellende Qualität erreicht wird. Eine Analyse der Literatur im Bereich des Einrichtens hat gezeigt, dass dies in der Regel einen einmaligen Vorgang darstellt. Auch heute werden die Prozessparameter in der Regel manuell vom Personal optimiert. So werden in vielen Fällen während der Entwicklung und der Inbetriebnahme eines Prozesses einmal die Prozessparameter definiert: sie werden entweder mithilfe von Simulationen oder mithilfe der realen Anlage ermittelt und dienen dann dem Mitarbeiter beim Einrichten als Grundlage. Der Mitarbeiter variiert anschließend mithilfe der Prozessdokumentation und seines Erfahrungswissens die Justagen solange, bis er eine zufriedenstellende Einstellung gefunden hat, die die momentan anliegenden Auswirkungen der Störgrößen hinreichend kompensiert. Der Schluss liegt nahe, dass ein Assistenzsystem, welches den Bediener hier unterstützt, Zeit und somit Kosten spart. Der Aufwand der nicht wertschöpfenden Tätigkeit würde reduziert und die effektive Maschinennutzungszeit erhöht.

Dem folgend wurde in Abschnitt 2.3 ein Überblick über Assistenzsysteme in der Produktion und deren mögliche Kategorisierung gegeben. So wurden Assistenzsysteme aus verschiedenen Perspektiven aus der Literatur erörtert. Die Sicht der Arbeitsgestaltung unterschied dabei zwischen dem Ziel, dem Grad und der Art der Unterstützung. Das Ziel kann kompensierend, erhaltend oder erweiternd bezüglich der menschlichen Fähigkeiten ausgeprägt sein. Die Art physischer, sensorischer oder kognitiver Natur und der Grad zwischen niedrig und hoch variieren. Aus Sicht der Logistik können Systeme in sechs unterschiedliche Komplexitätsstufen eingeteilt werden. Diese variieren von einfacher Datenaufnahme und Aufbereitung über der Generierung von Lösungsalternativen bis hin zur Überwachung der Entscheidungsausführung. Durch den fokussierten Blick auf die Logistik ist die Klassifikationssystematik speziell auf die in dem Bereich vorliegenden Herausforderungen zugeschnitten. Die letzte Perspektive waren die der Produktionsprozesse. Vergleichbar zu der Arbeitsgestaltung wurden informationstechnische, körperliche und kognitive Systeme unterschieden. Zusätzlich wurden in der Veröffentlichung, ähnlich zur Logistik, die Assistenzsysteme in Komplexitätsstufen unterteilt. Diese lassen sich in

vier unterschiedliche Stufen, der Signalisierung, der Beobachtung, der Prognose und der Unterstützung ausdifferenzieren. Es zeigt sich, dass eine einheitliche Klassifikationssystematik für Assistenzsysteme in der Produktion, die ebenfalls das Einrichten abbildet, noch nicht existiert. Im nächsten Schritt wurden kontextnahe Beispielasstistenzsysteme vorgestellt, die ausnahmslos in der Forschung situiert sind. Es wurde die Entwicklung

- eines Expertensystems für eine Werkzeugmaschine basierend auf einer symbolischen Regression,
- das Forschungsprojekt Cyberrüsten 4.0 für eine Biegemaschine,
- das Projekt APPsist und
- eine Veröffentlichung für eine Rüstassistentz für eine Webmaschine

vorgestellt. Aus diesen Beispielen lässt sich festhalten, dass eine allgemein anwendbare Systematik für eine quantitative Unterstützung beim Einrichten von Produktionsprozessen fehlt. Zwar werden zum Teil in der Forschung bereits Modelle zur Berechnung idealer Parameter genutzt, die Kompensation von (nicht messbaren) Störungen innerhalb dieser Assistenzsysteme wird jedoch nicht betrachtet.

Im nächsten Schritt, in Abschnitt 2.4 wurden datengetriebene Methoden in der Produktion beleuchtet. Als erste Methodengruppe wurden die etablierten Verfahren der Response-Surface-Methode inklusive der statistischen Versuchsplanung vorgestellt. So wurde zunächst das allgemeine Vorgehen von der Versuchsplanung bis zur Erstellung eines statistisch abgesicherten Regressionsmodells vorgestellt und die wesentlichen Werkzeuge kurz erläutert. Zu diesen Werkzeugen gehört neben den unterschiedlichen Versuchsplänen auch die Varianzanalyse (ANOVA), welche zur Beurteilung signifikanter Einflussgrößen herangezogen werden kann. Anschließend wurden kontextnahe Beispielanwendungen aus der Literatur näher erörtert, die diese Methoden nutzen. Auch hier hat sich das Bild bestätigt, dass im Falle einer Identifikation von Prozessparametern häufig nur eine einmalige Anwendung fokussiert wird. Die Annahme ist, dass die wesentlichen Einflussgrößen, also auch die Störgrößen, ermittelt werden können.

Ähnlich zur RSM werden auch die ML-Verfahren zur Approximation von vorhandenen Daten genutzt, diese Teildisziplin der Informatik erlebte in den letzten Jahren eine Renaissance. Diese ist damit begründet, dass aufgrund vermehrtem Sensoreinsatz und günstigem Speicher in vielen Fällen eine große Datenmenge zur Verfügung steht, die gewinnbringend analysiert werden kann. So wurden im Kontext dieser Arbeit zunächst die Grundlagen zu ML-Verfahren erläutert und eine übliche Vorgehensweise vorgestellt. Anschließend wurden analog zur statistischen Versuchsplanung Beispielanwendungen erörtert, welche einen Bezug im Kontext dieser Arbeit aufweisen. Hierbei wurden zum einen Anwendungen dargestellt, die Verfahren des maschinellen Lernens in der Produktion erfolgreich anwenden, als auch Anwendungen, die eine Kombination von Design of Experiments (statistische Versuchsplanung) (DoE) und ML vorschlagen. Bei letzterer kann zwischen der Datengenerierung durch DoE und der Hyperparameteroptimierung mittels der RSM unterschieden werden. Die Analyse der Forschungsbeiträge hat gezeigt, dass die ML-Verfahren auch im Produktionsumfeld zur Approximation des Prozessverhaltens vielversprechende Ergebnisse liefern und so ebenfalls einen wichtigen Platz neben den etablierten Verfahren in den letzten Jahren eingenommen haben. Aber auch in diesen Beispielen werden anhand einer initial aufgenommenen Datenbasis einmalig optimierte Pa-

parameter ermittelt. Eine Berücksichtigung der aktuellen Produktqualität findet in der Regel nicht statt.

Fazit

Aus dem Stand der Technik lässt sich folglich ableiten, dass...

- ... es eine Vielzahl unterschiedlicher Produktionsverfahren gibt. Zur Herstellung von Produkten werden Produktionsprozesse eingesetzt, die ein erhebliches Expertenwissen benötigen und mithilfe von Stell- und Störgrößen beeinflusst werden.
- ... diese Einflussgrößen in einer Produktqualität resultieren, die mithilfe von Qualitätsmerkmalen beschrieben wird.
- ... Produktionsprozesse auch in der heutigen Zeit noch nicht vollständig automatisiert und digitalisiert sind, wir befinden uns in einer Transition inmitten von gesteuerten und autonomen Produktionssystemen.
- ... durch eine notwendige flexible Produktion die Prozesse immer häufiger umgerüstet werden müssen. Das Umrüsten muss so kurz wie möglich gehalten werden - das Einrichten der Werkzeuge spielt hierbei eine wesentliche Rolle.
- ... bereits heute eine Vielzahl unterschiedlicher Assistenzsysteme eingesetzt werden. Diese sind in der Regel qualitativer Natur, eine quantitative Unterstützung des Maschinenbedieners fehlt.
- ... eine Klassifikationssystematik der Assistenzsysteme zugeschnitten auf Einrichtungssysteme noch nicht in der Literatur existiert, diese würde bei einem Vergleich der verschiedenen Systeme helfen und diese strukturieren.
- ... es bereits etablierte Verfahren zur Entwicklung der quantitativen Assistenzsysteme existieren. Diese müssen in geeigneter Weise genutzt werden, um eine allgemeingültige Systematik zur Entwicklung solcher Einrichtungssysteme zu definieren.
- ... in der Literatur häufig einmalig optimierte Prozessparameter bestimmt werden. Für eine laufende Produktion ist dies durch variierende Umgebungsbedingungen nicht geeignet und muss in den Assistenzsystemen Berücksichtigung finden.

Basierend auf dieser Zusammenfassung ergeben sich die drei folgenden Forschungsfragen, die in dieser Arbeit beantwortet werden:

- 1. Wie können Produkte in einer flexiblen Produktion, auch bei gering automatisierten Prozessen, weiterhin wirtschaftlich produziert werden?**
- 2. Wie ist eine Systematik ausgestaltet, die bei Befolgung ein Assistenzsystem für das Einrichten von Produktionsprozessen erstellt, um einen Maschinenbediener quantitativ beim Einrichten zu unterstützen?**
- 3. Wie können messbare und nicht-messbare Störungen in diesem System berücksichtigt werden, sodass dieses direkt von Produktionsbeginn an genutzt werden kann?**

3 Entwicklung einer Systematik für Einrichtassistentensysteme

In diesem Kapitel wird basierend auf den Ergebnissen des Stands der Technik eine Systematik für die Entwicklung intelligenter EAS erarbeitet. Hierfür wird zunächst basierend auf Abschnitt 2.3 eine neue Klassifikation entwickelt, um Assistenzsysteme insbesondere im Hinblick auf den Einrichtprozess charakterisieren zu können. Anschließend werden generalisierte Anforderungen sowie Rahmenbedingungen aus den fokussierten Produktionsprozessen abgeleitet (Abschnitt 3.2) und im nächsten Abschnitt das notwendige Assistenzsystem eingeordnet. Sie bilden somit das Fundament für die Entwicklung einer Referenzarchitektur (Abschnitt 3.3). Diese beinhaltet neben einem Gesamtüberblick, die Modelle, sowie eine Kompensationsstrategie für nicht messbare Störungen und nicht berücksichtigte Einflüsse. Abschließend wird eine Vorgehensweise zur Bearbeitung der Systematik vorgestellt (Abschnitt 3.4).

Begriffsdefinitionen

In dieser Arbeit stellt das System für den Produktionsprozess (siehe Abbildung 3-1) eine zentrale Rolle dar. Aus diesem Grund werden an dieser Stelle Begriffe definiert, um ein einheitliches Verständnis zu gewährleisten. Das allgemeine System entspricht demnach einem Produktionsprozess. In Anlehnung an [FKL⁺13] gibt es zwei unterschiedliche Arten von Einflussgrößen, die auf das Systemverhalten wirken.




Bild 3-1: Überblick über das System Produktionsprozess

Die erste Art sind die **Stellgrößen** $\mathbf{x}_k$. Diese Art der Einflussgrößen zeichnet sich dadurch aus, dass sie signifikante Auswirkungen auf das System hat. Des Weiteren ist sie innerhalb eines definierten Bereichs kontrolliert einstellbar [FKL⁺13]. Dieser Bereich wird im Kontext der Arbeit Parameterraum genannt. Im Gegensatz zu den meist dynamischen Betrachtungen der Regelungstechnik, können diese beim Einrichten als initialen Prozess vernachlässigt werden. Somit wird in dieser Arbeit das stationäre Verhalten des Prozesses betrachtet und die Auswirkungen der Stellgrößen nach dem Einschwingen interpretiert. In der Domäne der Produktionstechnik können die Stellgrößen beispielsweise Maschinenparameter, mechanische Eingriffsstellen oder Aktorzustände sein. In der Literatur zu Produktionsprozessen wird häufig einfach generell von Prozessparametern gesprochen. Im Bereich der statistischen Versuchsplanung von kontrollierbaren Faktoren [Mon13; SvH10] und im Bereich des maschinellen Lernens von Merkmalen (engl. *features*). Es ist ersichtlich, dass jede Teildisziplin ihre eigene Nomenklatur besitzt: in dieser Arbeit wird der Begriff der Stellgrößen verwendet.

	kontrollierbar	nicht-kontrollierbar
messbar	Stellgröße	Störgröße
nicht-messbar	-	Störgröße

Bild 3-2: Klassifikation der Einflussgrößen eines Prozesses

Wie in Abbildung 3-1 zu sehen, existieren neben den Stellgrößen, ebenfalls **Störgrößen** x_{nk} , die das Systemverhalten beeinflussen. Diese sind dadurch charakterisiert, dass sie nicht kontrollierbare Einflussgrößen sind. Ihr Verhalten kann nicht vorhergesagt [FKL⁺13], sowie zum Teil auch nicht gemessen werden (siehe Abbildung 3-2). In der statistischen Versuchsplanung wird bei dieser Kategorie von nicht kontrollierbaren Faktoren [Mon13] gesprochen und sofern die Störungen messbar sind, würden diese ebenfalls den Merkmalen bei den maschinellen Lernalgorithmen zugeordnet. In dieser Arbeit wird für eine einheitliche Nomenklatur der Begriff Störgrößen genutzt.

Beide Arten der Einflussgrößen ändern das Systemverhalten und damit die Ausgangsgröße [FKL⁺13], also das Ergebnis [SvH10] des Produktionsprozesses y . Im Bereich des maschinellen Lernen wird dies als Output oder auch als Label klassifiziert. Das Ergebnis sind in dem Kontext dieser Arbeit **Produkte**, die gewisse Eigenschaften oder Produktmerkmale aufweisen. Beispiele hierfür sind geometrische Eigenschaften wie Längen, Winkel oder Dicken. Des Weiteren können ebenfalls Materialkenngrößen (wie zum Beispiel Festigkeiten, Eigenspannungen oder auch Martensitanteile) eine signifikante Rolle für das Produkt spielen. Die Produktmerkmale sind dabei direkt die Eigenschaften, die das Produkt aufweisen soll, um die Erwartungen des Kunden zu erfüllen. Auch heute werden nicht alle Produktmerkmale direkt ermittelt, da sie nur mit hohem technischen Aufwand und damit nicht wirtschaftlich messbar sind. Die Produktmerkmale sind eine Teilmenge der Produktqualitätsmerkmale. Beispielhaft kann eine Temperatur in einem dedizierten Prozessschritt ein Qualitätsmerkmal sein, weil sich erst bei Erreichen dieser ein notwendiges Gefüge einstellt. Ein Produktmerkmal kann die Temperatur im späteren Verlauf nicht mehr sein, dies wäre dann der (meist messtechnisch aufwändigere) Nachweis des Gefüges. In dieser Arbeit wird daher beim Ausgang zwischen Produkt- und Qualitätsmerkmalen unterschieden.

3.1 Klassifikationssystematik

Im Folgenden wird zunächst die Klassifikationssystematik für die Assistenzsysteme erarbeitet. Diese basiert auf den im Kapitel 2 erörterten Strategien zur Klassifikation aus der Literatur, führt sie zusammen und ergänzt diese. Ziel ist es, eine allgemeingültige Einordnung für Assistenzsysteme für das Einrichten zu entwickeln, um die in dieser Arbeit entwickelnde Systematik zu charakterisieren. Hierfür werden die einzelnen Klassifikationsmerkmale definiert und erörtert, um eine Einordnung zu ermöglichen. Wie in Abbil-

Kategorie		Ausprägung			
Unterstützungsziel		kompensierend		erweiternd	erhaltend
Unterstützungsart		informativ		kognitiv	
		psychisch		physisch	
technologische Komplexität	Datenaufnahme	manuell	teilautomatisiert	automatisiert	
	Datenverarbeitung	deskriptiv	diagnostisch	prädiktiv	präskriptiv
	Systemeingriff	manuell	teilautomatisiert	automatisiert	

Bild 3-3: Klassifikationssystematik von Assistenzsystemen

dung 3-3 illustriert, wird das EAS sowohl bezüglich

- des Unterstützungsziels des Systems in Bezug auf den Nutzer,
- der Unterstützungsart hinsichtlich der Auswirkungen auf den Menschen und
- der technologischen Komplexität

differenziert. Analog zu [ABP⁺18] wird das Unterstützungsziel in kompensierend, erweiternd und erhaltend unterteilt und bezieht sich jeweils auf die menschliche Fähigkeit eine Aufgabe zu bewältigen. Ein kompensierendes Assistenzsystem gleicht dabei Schwächen eines Individuums aus, die von dem Erwartungswert der Zielgruppe abweichen. Dies können sowohl alters-, aber auch krankheitsbedingte Schwächen sein. So können Exoskelette zum Beispiel eine altersbedingte Muskelatrophie ausgleichen, um schwerere Lasten zu bewegen.

Neben dem kompensierenden Unterstützungsziel können die Systeme ebenfalls fähigkeitserweiternd arbeiten. Hierbei gilt, dass die Fähigkeiten des Menschen durch das System so verbessert werden, dass der Erwartungswert der Zielgruppe übertroffen wird. Dies kann ebenfalls bedeuten, dass eine intensive Einarbeitung der Mitarbeiter in einen komplexen Sachverhalt vereinfacht wird oder sogar komplett entfallen kann. So kann sich ein ungeschulter Mitarbeiter mithilfe einer AR-Anwendung beispielhaft schneller in eine neue Montageanleitung einarbeiten als mit einer konventionellen Anleitung. Die letzte Unterklasse des Unterstützungsziels ist das fähigkeitserhaltende Assistenzsystem. Dieses unterstützt den Nutzer eine gesunde Arbeitsweise in den Alltag zu integrieren, um die Fähigkeiten zu erhalten. Exemplarisch kann ein System die Rückenbelastung des Nutzers beim Heben von Lasten analysieren und daraufhin Hinweise zum gesünderen Heben oder auch Warnungen zum aktuellen Vorgang ausgeben. Die Idee ist, dass die Gesundheit und somit die Fähigkeiten des Mitarbeiters konserviert werden.

Die nächste Kategorisierung ist die Unterstützungsart, die an [ABP⁺18; CSS18; Sch15] angelehnt ist. Sie kann sowohl informativ, psychisch, physisch als auch kognitiv ausge-

Kategorie	Ausprägung	
Unterstützungsart	informativ	kognitiv
	psychisch	physisch

Bild 3-4: Unterstützungsarten der Assistenzsysteme

prägt sein und steigt in der Komplexität ebenfalls in dieser Reihenfolge. Ein informatives Assistenzsystem zeigt dem Nutzer zusätzliche Informationen über das Zielsystem an und bereitet diese hierfür anwendungsgerecht auf. So werden Produktdaten, aber auch sensorisch erfasste Daten, als Grundlage genutzt und zur Anzeige aufbereitet. Ein Beispiel dieser Art ist eine Pick-by-Light Anwendung, welche als informatives Assistenzsystem betrachtet wird, da dem Nutzer die Information über das nächste zu montierende Bauteil bereitgestellt wird. Informative Systeme haben in der Regel eine geringere Komplexität bezüglich der Datenverarbeitung, da nur in geringem Maße eine Interpretation der Daten stattfindet.

Neben informativen Assistenzsystemen können ebenfalls psychisch unterstützende Systeme dem Nutzer bei seiner Arbeit helfen. Diese Ausprägung ist spezifisch an [CSS18] angelehnt und umfasst zum Beispiel Anwendungen, die die Vitaldaten des Probanden aufnehmen und verarbeiten, um ihm eine Zusammenfassung über seinen Arbeitsalltag zu geben. Aus Produktionssicht spielt diese Art eine untergeordnete Rolle, bei aufwendigeren Lagerarbeiten könnten Mitarbeiter durch einen Schrittzähler motiviert werden. Die nächst komplexere Kategorie ist die der physischen Assistenzsysteme, die den Nutzer bei körperlicher Arbeit unterstützen. Hierbei steht im Vordergrund, dass Arbeiten wie der Lasttransport, das Heben von Werkstücken oder auch das Arbeiten in unbequemen Positionen teilweise oder gänzlich reduziert werden. Beispiele sind kollaborative Robotersysteme, die dem Menschen bei seiner Arbeit flexibel assistieren oder auch die bereits genannten Exoskelette, die beim Tragen schwerer Lasten unterstützen.

Die letzte und damit komplexeste Ausprägung sind die kognitiv unterstützenden Systeme. Die Systeme assistieren bei der Entscheidungsfindung für das Zielsystem indem sie Wissen systematisch ablegen, analysieren und dem Nutzer Handlungsvorschläge zur Verfügung stellen oder ebenfalls umsetzen. Der Nutzer konsultiert das System, um die Komplexität des Zielprozesses beherrschbar zu machen. Ein Beispiel für ein kognitives System kann ein System zur prädiktiven Wartung (Predictive Maintenance) sein, welches dem Nutzer die nächsten Wartungsintervalle und -aktivitäten prognostiziert.

Die letzte Kategorie (siehe Abbildung 3-5) ist die technologische Komplexität des Assistenzsystems: diese wird in Anlehnung an [KKM⁺17] bereits auf kategorischer Ebene zusätzlich in Datenaufnahme und -verarbeitung, sowie dem Systemeingriff ausdifferenziert. So kann ein umfangreicheres Bild des Assistenzsystems auf Basis der wichtigen Komponenten erlangt werden. Die Datenaufnahme kann wiederum manueller, teilautomatisierter oder automatisierter Natur sein. Unter einer manuellen Datenaufnahme wird verstanden, dass der Nutzer die notwendigen Daten mit einem Messmittel händisch erfasst und diese

Kategorie		Ausprägung		
technologische Komplexität	Datenaufnahme	manuell	teilautomatisiert	automatisiert
	Datenverarbeitung	deskriptiv	diagnostisch	prädiktiv präskriptiv
	Systemeingriff	manuell	teilautomatisiert	automatisiert

Bild 3-5: Ausprägungen der technologischen Komplexität

manuell dem Assistenzsystem zuführt. Es ist naheliegend, dass hier sowohl die Reproduzierbarkeit der Messungen, als auch die Eindeutigkeit der Datenübertragung gewährleistet werden muss.

Eine teilautomatisierte Datenaufnahme kann in zweierlei Ausprägungen vorliegen: zum einen kann die Erfassung der Daten händisch durch den Nutzer erfolgen, indem er beispielsweise ein Produkt in eine Messstation legt. Diese ermittelt anschließend die Werte und überträgt sie automatisiert über eine Schnittstelle an das Assistenzsystem. Zum anderen kann die Erfassung der Qualitätsmerkmale inline, also automatisiert, erfolgen, allerdings existiert keine elektronische Schnittstelle zum Assistenzsystem, sodass hier der Nutzer die Schnittstelle darstellt und die Daten zum Assistenzsystem überträgt. Bei einer automatisierten Datenaufnahme hat der Nutzer hingegen nur überwachenden Charakter, ein aktives Eingreifen ist nur in Ausnahmefällen notwendig.

Nach der Datenaufnahme und der Übertragung an das Assistenzsystem müssen die Daten verarbeitet werden, welches die nächste Subkategorie der technischen Komplexität darstellt. Die Datenverarbeitung kann in Anlehnung an [KKM⁺17; NRMM15; KJR⁺18] deskriptiv, diagnostisch, prädiktiv oder präskriptiv ausgeprägt sein. Die Ausprägungen bauen aufeinander auf und somit nimmt die Komplexität der Algorithmen in gleicher Reihenfolge zu. Eine deskriptive Datenverarbeitung liegt vor, wenn mithilfe der Verarbeitungsalgorithmen der Systemzustand beschrieben wird. Hierbei können zum einen dem Nutzer nur direkt ermittelte Größen zur Verfügung gestellt, zum anderen aber auch abgeleitete Größen genutzt werden. Beispiele wären hierfür die Schätzung von Zustandsgrößen mithilfe eines Beobachters oder die Ableitung weiterer Messgrößen über eine Sensorfusion [KAS⁺16; HLL09; DPB⁺16]. Das Ziel ist dementsprechend eine Zustandsbeschreibung des Zielsystems ohne diesen in einen Kontext zu setzen oder zu interpretieren. Exemplarisch für diese Ausprägung wäre ein System, welches eine Temperatur für den Bediener aufbereitet anzeigt. Eine diagnostische Datenverarbeitung liegt vor, wenn anhand des Systemzustands das aktuelle Verhalten in den Kontext der Maschinennutzung gebracht und bewertet wird. Hierbei ist von Bedeutung, dass sich der Zeithorizont bis zur Gegenwart erstreckt: Aussagen über die Zukunft werden nicht getroffen. In dieser Ausprägung würde die Temperaturanzeige ergänzt durch eine Grenzwertüberwachung und weitergehend ggf. durch eine Analyse der Ursachen. Beispielhaft könnten dies Heiz- oder Lüftungselemente in dem System sein, die ein Fehlverhalten verursachen.

Die nächst komplexere Ausprägung ist die prädiktive Datenverarbeitung. Im Gegensatz

zur Diagnose wird hier durch Analysen eine Vorhersage des zukünftigen Verhaltens des Zielsystems getroffen, indem historische Daten ausgewertet und mit dem aktuellen Systemzustand und -verhalten verglichen werden. Ein momentaner Forschungsgegenstand ist die prädiktive Wartung (engl. *predictive maintenance*), die einen häufigen Anwendungsfall der prädiktiven Datenverarbeitung darstellt. Durch eine Erweiterung der oben beschriebenen Temperaturdiagnose um eine Vorhersage der restlichen Lebensdauer der Heizelemente, wäre hier eine prädiktive Datenverarbeitung vorhanden. Die präskriptive Datenverarbeitung stellt die letzte und komplexeste Ausprägung dar. Während in der vorherigen Stufe ermittelt wird, dass und wann etwas passieren wird, wird in dieser Stufe vorhergesagt, wie ein System manipuliert werden muss, damit sich ein gewisser Zielzustand einstellt. Es wird sowohl eine Vorhersage über den Zustand des Systems errechnet, als auch über die Ursachen dafür. Am Beispiel der Heizelementprädiktion wäre die Präskription in diesem Fall die Vorhersage, warum die Heizelemente ausfallen und wie dies entweder zukünftig vermieden wird oder wie sich das System nun verhalten muss, um die Lebensdauer der Heizelemente zu maximieren.

Die letzte Kategorie ist die technologische Komplexität des Systemeingriffs. Analog zur Datenaufnahme wird hier ebenfalls zwischen einem manuellen, teilautomatisierten und automatisierten Eingriff differenziert. Ein manueller Systemeingriff liegt vor, wenn der Nutzer des Assistenzsystems über eine Schnittstelle informiert wird, wie er das Zielsystem zu beeinflussen hat und dies durch eine eigene Aktivität an dem Zielsystem realisiert wird. Dies kann beispielsweise ein Werkzeugwechsel durch den Bediener sein oder eine Justage der Anlage. Ein teilautomatisierter Systemeingriff liegt vor, wenn Aktoren bereits in das Zielsystem integriert sind, die Informationen über die Aktoreinstellungen jedoch vom Menschen übertragen und sichergestellt werden. Beispielhaft hierfür können Positionseinstellung einer Walze von einem Assistenzsystem hinsichtlich der Produktqualität optimiert werden. Das System gibt dem Bediener neue Sollgrößen für die Walzpositionen vor. Ein automatisierter Systemeingriff liegt vor, wenn der Nutzer über eine Schnittstelle Handlungsempfehlungen vom Assistenzsystem bekommt und diese eigenständig vom System umgesetzt werden. Hierbei kann ebenfalls eine optionale Kontrolle und Bestätigung der Handlungsempfehlungen durch den Bediener erfolgen. Beispielhaft ist hier ein kollaborativer Roboter, der einem Menschen bei der Verschraubung an einer schwer zugänglichen Stelle unterstützt.

Fazit

In diesem Abschnitt wurde basierend auf dem Stand der Technik (siehe dazu Abschnitt 2.3.1) eine Klassifikationssystematik für Assistenzsysteme entwickelt. Diese charakterisiert Assistenzsysteme nach ihrem Unterstützungsziel, der -art und der technologischen Komplexität. Die Klassifikationssystematik ist eine Zusammenführung unterschiedlicher Veröffentlichungen aus dem Stand der Technik. Sie dient nun als Grundlage für eine Charakterisierung des in dieser Arbeit entwickelten EAS und für eine strukturierte Abgrenzung zu vorhandenen im Stand der Technik vorgestellten Assistenzsystemen. Vorbereitend werden im nächsten Abschnitt 3.2 die Rahmenbedingungen und Anforderungen an ein EAS erörtert.

3.2 Rahmenbedingungen und Anforderungen

Folgend werden nun die aus der Forschungsfrage resultierenden Rahmenbedingungen kurz zusammengefasst und die daraus folgenden Anforderungen erörtert. Dies ist die Grundlage zur Identifikation der notwendigen Charakteristika für die Systematik des EAS. Basierend darauf wird eine allgemeine Referenzarchitektur abgeleitet. Hierfür wird zunächst das Umfeld des Einrichtens in der Produktion charakterisiert.

Der Stand der Technik hat aufgezeigt, dass Produktionsprozesse auch heute noch in vielen Bereichen zunächst manuell von einem Bediener gerüstet werden. Hierbei steht im Vordergrund, dass die vom Kunden benötigte Produktqualität (zum Beispiel Toleranzen oder Materialeigenschaften) eingehalten wird. Konterkariert wird die Qualität durch die geforderte und zugesagte Lieferzeit: Produkte müssen in immer kürzeren Zeiten mit einer hohen Qualität zum Kunden ausgeliefert werden. Aufgrund dieser Herausforderung und dem Wunsch der Kunden nach individualisierten Produkten werden kleinere Losgrößen produziert. Somit wird zum einen gebundenes Kapital reduziert und zum anderen die Möglichkeit geschaffen kundenindividuell zu reagieren.

Da Produktionsprozesse Produkte in immer kürzeren Intervallen fertigen müssen, sind die Mitarbeiter in der Produktion damit konfrontiert eine Vielzahl unterschiedlicher Werkzeuge innerhalb kürzester Zeit rüsten und somit neu einrichten zu müssen. Durch die hohe Werkzeugvielfalt von z.T. mehreren hundert bis tausend Werkzeugen ist es nicht möglich, dass die Mitarbeiter die Werkzeuge kennen, sondern sich in der Regel stetig neu einarbeiten müssen. Erschwerend kommt hinzu, dass diese Prozesse häufig mehrstufig sind und somit der Aufbau einer Intuition für diese Prozesse langwierig ist. Zwar werden bereits während der Prozessentwicklung Modelle genutzt, allerdings wird dieses Erfahrungswissen (wie zum Beispiel durch FE-Simulationen) häufig nicht für die Mitarbeiter im Produktionsumfeld aufbereitet. Das Ein-/Ausgangsverhalten ist in diesem Stadium nicht quantitativ bekannt.

Das Einrichten, als Teil des Rüstens, stellt hierbei die oben angesprochene Qualität sicher. Beim Einrichten justiert der Mitarbeiter die kontrollierbaren Prozessparameter bis die notwendige Qualität erreicht ist. Durch die steigende Komplexität der Produktionsprozesse kann dies eine erhebliche Zeit in Anspruch nehmen und somit durch Produktionsausfall und Personaleinsatz hohe Kosten verursachen. Die Komplexität beim Einrichten zeigt sich durch Prozesse, deren kontrollierbare Parameter miteinander wechselwirken und somit nichtlineare Einflüsse auf die Produktmerkmale ausüben. Dies verkompliziert das Einrichten für den Bediener. In der Produktion existieren vielfältige Prozesse mit unterschiedlichen Werkzeugen. Das Wissen über den Prozess wird häufig von den Mitarbeitern unsystematisch durch Versuch und Irrtum erworben und personenindividuell stetig verfeinert. Systematische Vorgehensweisen, wie in den wissenschaftlichen Veröffentlichungen aus dem Stand der Technik, finden seltener Anwendung. Durch die Vorgehensweise kann es zu einer Korrelation von Einfluss- und Qualitätsgrößen kommen, die nicht in einer Ursache-Wirkungsbeziehung stehen. Zusätzlich problematisch an dem Wissen in den Köpfen der Mitarbeiter ist, dass ein Ausscheiden dieser ebenfalls zu einem Wissensverlust für das Unternehmen und somit für die Produktion führt. Dies gilt es zu vermeiden oder zu reduzieren.

Aufgrund der Automatisierung und der Digitalisierung sind in den Produktionsstätten bereits eine Vielzahl unterschiedlicher Sensoren und Aktoren integriert. Sie werden für

die Prozess- und Qualitätsüberwachung genutzt und unterstützen die Mitarbeiter beim Einrichten der Werkzeuge durch ein Feedback über die Produktqualität. Beispiele hierfür sind Kameras, Distanzsensoren oder auch Waagen zur Gewichtsmessung. Der Trend geht zu einer erweiterten Überwachung der Qualität, die bereits beim Rüsten, speziell beim Einrichten, einen Mehrwert bieten kann.

Fazit

Zusammenfassend werden folgende Aussagen über die Rahmenbedingungen festgehalten:

1. Produktionsprozesse werden auch heute noch manuell eingerichtet, um die geforderte Qualität zu gewährleisten.
2. Aktuelle Trends führen zu einer Produktion kleinerer Losgrößen: Prozesse müssen häufiger umgerüstet und somit eingerichtet werden.
3. In der heutigen Produktionslandschaft werden vielfältige Sensoren eingesetzt, um den Prozess und die Qualität zu überwachen. Es gilt, diese gewinnbringend zu nutzen.
4. Mitarbeiter können nicht jedes Werkzeug kennen und das Einrichten ist komplex, daher würde eine quantitative Unterstützung Kosten und Zeit sparen.

Anforderungen

Aus den gegebenen Rahmenbedingungen der Produktionslandschaft und der darauf aufbauenden Charakterisierung des EAS lassen sich folgende Anforderungen an das System ableiten. Die Integration eines neuen Werkzeugs oder Prozesses muss einfach sein. Um von den Mitarbeitern akzeptiert und genutzt zu werden, muss sowohl die Wissensgenerierung als auch die -nutzung einen Vorteil gegenüber der konventionellen Variante bieten. Das bedeutet auch, dass das Wissen idealerweise bei der Entwicklung des Werkzeugs gewonnen wird und so die Systematik des EAS direkt genutzt werden kann. Zusätzliche Aufwände, wie zum Beispiel zur Entwicklung physikalischer Modelle, sollten vermieden werden - wenn diese Vorhanden sind, wird das Wissen genutzt.

Das System muss mit unterschiedlich ausgeprägten Automatisierungsgraden genutzt werden können. Wie in Kapitel 2 beschrieben, sind die Sensorausstattung der diversen Produktionsprozesse unterschiedlich stark ausgeprägt. Einige Prozesse haben weder Sensoren zur Qualitätsüberwachung noch Aktoren für einen Systemeingriff, andere wiederum überwachen jedes produzierte Bauteil und können ohne manuellen Eingriff justiert werden. Es müssen weiterhin mehrere Produktmerkmale als Kenngrößen für die Qualität berücksichtigt werden. Auch heute stellt die Ermittlung „der“ Qualität eines Bauteils zum Teil eine große Herausforderung dar. Zum einen erschweren zum Beispiel komplexe Bauteile eine Messung der qualitätsdefinierenden Merkmale und zum anderen gibt es Produktmerkmale, die nur mit hohem Aufwand inline gemessen werden können, wie Gefügezusammensetzung oder Festigkeit. Daher muss die Systematik des EAS mit verschiedenen Qualitätsmerkmalen arbeiten.

Aufgrund der Anwendung in der Produktion müssen Berechnungen robust sein und nicht kontrollierbare Einflüsse müssen kompensiert werden können. Weiterhin existieren in der




Bild 3-6: Zusammengefasste Anforderungen in einem Netzdiagramm zur späteren Bewertung

Produktion häufig Einflüsse auf die Prozesse, die entweder unbekannt oder nicht messbar (aufgrund wirtschaftlicher Betrachtungen oder kaum messbarer Größen, wie einigen Verschleißerscheinungen) sind: diese müssen ebenfalls kompensiert werden, um die Qualität des EAS und folglich des Zielprodukts zu maximieren. Das EAS sollte idealerweise dazu lernen: es sollte mit fortlaufender Nutzung an Präzision gewinnen. Zwar soll die Einrichtungunterstützung von Beginn des Lebenszyklus an nutzbar sein, allerdings muss ebenfalls die Möglichkeit vorgesehen werden das Wissen über den Prozess stetig zu erweitern. So sollen Störgrößen nach einiger Zeit zusätzlich berücksichtigt werden, um eine maximale Qualität beim Einrichten innerhalb weniger Iterationen zu erreichen. Das Wissen über solche Störungen kann dann ebenfalls in die Entwicklung zurückgeführt werden, um die Prozesse weiter konstruktiv zu optimieren.

Fazit

Eine quantitative Unterstützung beim Einrichten von Produktionsprozessen würde Kosten und Zeit sparen. Es fehlt ein System, welches den Bediener bei der Einrichtung unterstützt. An das EAS werden zusammenfassend die im Netzdiagramm der Abbildung 3-6 visualisierten Anforderungen gestellt.

1 Übertragbarkeit

Die einfache Implementierung eines neuen Prozesses ohne großen Aufwand für Modellentwicklungen ist erforderlich. Dies stellt die Nutzung für unterschiedliche Prozesse und deren Werkzeuge sicher.

2 Flexibilität

Eine Nutzung mit unterschiedlich automatisierten Prozessen muss vorgesehen werden.

3 Bedienbarkeit

Eine einfache Nutzung des EAS im Produktionsbetrieb ist notwendig. Der Bediener muss zielgerichtet unterstützt werden und benötigt daher nur die für ihn wesentlichen Informationen.

4 Konfigurierbarkeit

Eine prozessindividuelle, unbestimmte Anzahl relevanter Einfluss- und Zielgrößen muss berücksichtigt werden können.

5 Robustheit

Eine Kompensation nicht-messbarer Störungen ist erforderlich, da für die betrachteten Produktionsprozesse nicht alle relevanten Einflüsse messtechnisch erfasst werden.

6 Effizienz

Der frühzeitige Einsatz im ersten Produktionsintervall muss möglich sein, um direkt einen Mehrwert zu schaffen.

7 Lernfähigkeit

Eine kontinuierliche Verbesserung des Systems durch produktionsbegleitendes Lernen ist erstrebenswert, um das Einrichtergebnis stetig zu verbessern.


Zur späteren Bewertung der Anforderungserfüllung in Abschnitt 3.5 wird die Erfüllung der definierten Anforderungen in dem Netzdiagramm eingezeichnet. Die erste Stufe wird als „keine Erfüllung der Anforderung“, die letzte als „volle Erfüllung der Anforderung“ definiert. An dieser Stelle ist festzuhalten, dass eine Architektur benötigt wird, die einen einfachen Einsatz des EAS ermöglicht. Diese muss durch eine hohe Abstraktion flexibel sein, um unterschiedlichsten Prozessen zu genügen. Weiterhin ist vorzusehen, dass sowohl kurz- als auch langfristig aufgebautes Wissen integriert werden muss, da ein schneller Einsatz in der Produktion eine intensive Untersuchung aller Einflussgrößen verhindert. Auf Basis dieser Anforderungen wird nun anhand der Klassifikationssystematik das EAS charakterisiert.

Charakterisierung der Systematik für Assistenzsysteme

Basierend auf der Klassifikationssystematik, den Rahmenbedingungen und den daraus abgeleiteten Anforderungen wird nun die zu entwickelnde Systematik für EAS näher erörtert und klassifiziert (siehe Abbildung 3-8), um anschließend ein genaueres Bild von der notwendigen Architektur zu skizzieren. Der Zielzustand der Systematik ist die Befähigung zur Entwicklung eines Einrichtassistenten und schematisch in Abbildung 3-7 zu sehen. Der Bediener konsultiert den Einrichtassistenten, um eine Handlungsempfehlung für den Einrichtprozess zu bekommen. Hierfür

- liegt systematisch abgelegtes Wissen über den Prozess und die Sollqualitätsmerkmale vor,
- die aktuellen Qualitätsmerkmale werden analysiert,
- ideale Stellgrößen für die momentane Situation berechnet und
- abschließend dem Nutzer zur Verfügung gestellt.

Das zu entwickelnde System unterstützt den Nutzer bei der Entscheidungsfindung hinsichtlich der Stellgrößeneinstellungen für den Einrichtprozess. Hierfür stehen dem Ein-

Bild 3-7: Schema des unterstützten Einrichtprozesses, nach [GSH⁺ 18]

Kategorie		Ausprägung		
Unterstützungsziel		kompensierend	erweiternd	erhaltend
Unterstützungsart		informativ	kognitiv	
		psychisch	physisch	
technologische Komplexität	Datenaufnahme	manuell	teilautomatisiert	automatisiert
	Datenverarbeitung	deskriptiv	diagnostisch	prädiktiv
	Systemeingriff	manuell	teilautomatisiert	automatisiert

Bild 3-8: Einordnung des Ziel-EAS in die Klassifikationssystematik

richtassistenten neben den Sollqualitätsmerkmalen ebenfalls die momentanen Qualitätsmerkmale der gefertigten Produkte zur Verfügung.

Die gesamte Charakterisierung mithilfe der entwickelten Klassifikationssystematik ist in Abbildung 3-8 illustriert. Das Unterstützungsziel des EAS ist eine Erweiterung der menschlichen Fähigkeiten beim Einrichten. Wie in Kapitel 2 beschrieben, existieren komplexe, nichtlineare Auswirkungen der kontrollierbaren und nicht-kontrollierbaren Einflüsse auf die Qualitätsmerkmale. In der Regel liegen die menschlichen Stärken in der Einschätzung und Bewertung von linearen, nicht gekoppelten Auswirkungen: Nichtlinearitäten erfordern ein höheres Maß an Erfahrung und gestalten somit den Einrichtprozess schwieriger. Aufgrund dieses Umstands findet weder eine Kompensation noch eine Erhaltung der menschlichen Fähigkeiten statt. Die Fähigkeiten des Bedieners werden durch das EAS grundlegend erweitert mit der Fähigkeit eines systematischen Einrichtens des Produktionsprozesses unter Berücksichtigung der Randbedingungen und komplexen Nichtlinearitäten des Systems. Dies zeigt, dass das zu entwickelnde System den Menschen primär kognitiv unterstützen soll, allerdings ebenfalls informative Charakteristika aufweist. Diese sind jedoch Mittel zum Zweck und nicht im Fokus des EAS.

Kategorie	Abk.	Stufe 1	Stufe 2	Stufe 3	Stufe 4
Ziel	Z	kompensierend	erweiternd	erhaltend	-
Art	A	informativ	psychisch	physisch	kognitiv
Datenaufn.	DA	manuell	teilautom.	autom.	-
Datenverarb.	DV	deskriptiv	diagnostisch	prädiktiv	präskriptiv
Systemeingriff	SE	manuell	teilautom.	autom.	-




Bild 3-9: Erklärungstabelle und zugehöriges Netzdiagramm zur Charakterisierung des in dieser Arbeit zu entwickelnden EAS (orange)

Insbesondere bei der technischen Komplexität kann das System im Allgemeinen nicht auf singuläre Charakteristika festgelegt werden, da hier eine prozessindividuelle Lösung benötigt wird. Bei der Datenaufnahme existieren in der Produktion viele diverse und unterschiedlich automatisierte Verfahren. So können wesentliche Systemgrößen manuell gemessen und in das System übertragen werden, andere können ggf. teilautomatisiert oder gar vollständig automatisiert integriert werden. Aus diesem Grund kann diese Ausprägung nicht genau spezifiziert werden, die Architektur des EAS muss dementsprechend offen gehalten werden. Ähnliches gilt für den Systemeingriff, auch dieser ist prozessindividuell auszugestalten. So ist bei einigen Prozessen ein manueller Eingriff notwendig, da entsprechende Hardware in Form von Aktorik fehlt, bei anderen Prozessen kann hingegen ein vollständig automatisierter Eingriff in den Prozess stattfinden. Die technische Komplexität bezüglich der Datenverarbeitung ist bei dem hier notwendigen System präskriptiv einzuordnen. So muss für das EAS anhand des aktuellen Systemzustands und der aktuellen Systemeingänge, wie zum Beispiel Software-Parameter oder Stellgrößen, eine Prädiktion des zukünftigen Verhaltens erstellt werden. Anhand dieser Vorhersage wird anschließend unter Berücksichtigung des Modellwissens berechnet, wie das Zielsystem manipuliert werden muss, um den gewünschten Zustand, sprich die benötigten Qualitätsmerkmale, herzustellen.

Existierende Assistenzsysteme

Es folgt ein Vergleich des charakterisierten EAS mit den in Kapitel 2.3 vorgestellten Systemen. Zur Übersicht werden die Systeme mittels Netzdiagrammen veranschaulicht, um die Differenzen und Gemeinsamkeiten übersichtlich darzustellen. In Abbildung 3-9 ist das in dieser Arbeit zu entwickelnde System dargestellt - es gilt: die Komplexität des Ziel-EAS der Systematik in der jeweiligen Kategorie steigt mit der Entfernung vom Mittelpunkt.

Das erste betrachtete Assistenzsystem ist die Entwicklung aus dem Projekt „Cyberrüsten 4.0“ (siehe [DHK⁺16]) für eine Rohrbiegemaschine. Auch dieses Assistenzsystem (siehe Abbildung 3-10 a) hat als Unterstützungsziel die Erweiterung der Fähigkeiten des Nutzers, da es diesen durch die Bedienung der Maschine führt und so die Effizienz steigert. Bei der Unterstützungsart hingegen würde das System einem informativen Charakter entsprechen, da die Informationen eher angezeigt werden und der Nutzer nicht bei tiefgehenden Entscheidungen zu der Anlage unterstützt wird. Die Datenaufnahme, sowie der Systemeingriff sind händischer Natur, da der Bediener über eine Mixed-Reality-Brille die




Bild 3-10: Vergleich der betrachteten Assistenzsysteme (blau) zum EAS dieser Arbeit (orange)

Informationen, wie Videos angezeigt bekommt und diese eigenhändig umsetzt. Die Aufnahme momentaner Daten der Maschine geht aus den vorhandenen Veröffentlichungen [DHK⁺16] ebenfalls nicht hervor. Bei der Datenverarbeitung wird auf deskriptive Analysen gesetzt und der Benutzer durch vorgefertigte Analysen unterstützt. Aufgrund eines ähnlichen Lösungsansatzes für das Rüsten einer Webmaschine in [WK18] ist dieses Assistenzsystem ähnlich einzuordnen.

Auch das APPsist-Projekt [PKK17] hat die Fähigkeitserweiterung als Unterstützungsziel im Hinblick auf eine informative Unterstützung des Mitarbeiters (siehe Abbildung 3-10 b), da hier zum Beispiel Daten für das Zielsystem aufbereitet werden, um diese dem Nutzer darzustellen - ähnlich zu einer Pick-by-Light Anwendung. Die in den Veröffentlichungen vorgestellte technische Komplexität der Datenverarbeitung hat insbesondere aufgrund der Ontologie eine höhere Ausprägung, allerdings werden keine tiefgehenden Analysen des Zielsystems vorgestellt und besitzt somit deskriptiven bis diagnostischen Charakter. Bei der technischen Komplexität wird ein hybrides System aus manueller, teilautomatisierter, aber auch automatisierter Datenerfassung erarbeitet; aus diesem Grund wird in der Abbildung die automatisierte Datenaufnahme abgebildet. So kann der Bediener selbst Daten erfassen und im System eingeben und wird dabei durch Daten aus dem maschinennahen System aber auch dem Planungssystem unterstützt. Hier kann demnach keine eindeutige Zuordnung getroffen werden. Durch den direkten Einbezug des Bedieners zur Nutzung der Benutzerschnittstelle (HMI) wird in dem APPsist-System ein manueller Eingriff in das System vorgesehen. Zu diesem System ist jedoch anzumerken, dass es aufgrund der Struktur und potenziellen Informationsquellen die Möglichkeit bietet noch weit komplexere Analysen perspektivisch zu integrieren.

Als letztes EAS wird das Expertensystem für einen Fräsprozess aus [TEGP13] betrachtet (siehe Abbildung 3-10 c). Auch dieses System hat das Ziel, die Fähigkeiten des Bedieners für das Einrichten des Prozesses zu erweitern, indem optimierte Prozessparameter berechnet werden. Hierbei ist die Unterstützungsart dem kognitiven Assistieren zuzuordnen, da der Mensch bei dem Einschätzen des Maschinenverhaltens quantitativ unterstützt wird. Zur Interaktion zwischen Mensch und Maschine werden in diesem System für den Systemeingriff manuelle Tätigkeiten vorgesehen, wobei die Datenaufnahme automatisierter Natur ist. Die Datenverarbeitung ist präskriptiver Natur, da die Frage beantwortet wird, wie der Bediener die Maschine zukünftig einzustellen hat, damit eine optimale Qualität erreicht wird. Wie bereits im Stand der Technik (Kapitel 2) angedeutet, werden in diesem System jedoch allein die Stellgrößen des Systems betrachtet. Messbare und nicht messbare Störgrößen finden keine Berücksichtigung.

Fazit

Mithilfe der Rahmenbedingungen für das EAS wurden Anforderungen an das System abgeleitet und das System mit der entwickelten Klassifikationssystematik näher charakterisiert. Es hat sich gezeigt, dass für das Einrichten ein kognitives, fähigkeits-erweiterndes System benötigt wird, welches präskriptive Analysen für das Zielsystem liefert. Die Datenaufnahme und der Systemeingriff müssen flexibel anpassbar sein, um den verschiedenen Automatisierungsgraden gerecht zu werden. Weiterhin konnte das zu entwickelnde EAS von den im Stand der Technik vorgestellten Systemen abgegrenzt und der Mehrwert aufgezeigt werden. Diese Grundlagen werden nun für die Entwicklung einer Referenzarchitektur genutzt, die diese Anforderungen hinreichend erfüllt. Diese Architektur wird abschließend im nächsten Kapitel anhand eines Beispielsprozesses validiert.

3.3 Entwicklung der Referenzarchitektur

Nach der Analyse der Rahmenbedingungen und der anschließenden Definition der Anforderungen an das EAS wird im folgenden Abschnitt die Referenzarchitektur erläutert. Hierfür wird zunächst ein Überblick über die Architektur und ihre Komponenten gegeben und abschließend die einzelnen Module ausdetailliert.

In Abbildung 3-11 ist das Zusammenspiel zwischen einem abstrakten Beispielsprozess und dem EAS zu sehen. Der **Produktionsprozess** wird von verschiedenen Größen, namentlich Stell- und Störgrößen, beeinflusst und produziert aufgrund dieser Einflüsse Produkte mit dedizierten Eigenschaften. Veranschaulicht bedeutet dies, dass ein Produktionsprozess aufgrund dieser Größen Produkte mit unterschiedlichen **Produkt- und Qualitätsmerkmalen** y fertigt. Produkt- und Qualitätsmerkmale können sowohl geometrischer Natur sein (wie Längen oder Winkel), die Prozessfähigkeit, aber auch die Materialeigenschaften betreffen (wie Zugfestigkeit, Härte oder Gefügezusammensetzung). In der Regel ist die Ermittlung „der“ Produktqualität nicht trivial, da zum einen zunächst die zu ermittelnden Qualitätsmerkmale des Produkts spezifiziert werden müssen und zum anderen die Messung dieser Merkmale mit der notwendigen Präzision unter Produktionsbedingungen eine Herausforderung darstellt. Häufig muss daher auf repräsentative Kenngrößen zurückgegriffen werden, die in Summe mit der eigentlichen Produktqualität korrelieren. Dies können zum Beispiel Merkmale aus Thermographiebildern eines Produkts kurz nach der Herstellung sein oder die Bestimmung der ferromagnetischen Eigenschaften als Korrelationsgröße für die Materialzusammensetzung. Diese beiden messbaren Gattungen der Einflussgrößen werden nun erfasst und für das EAS genutzt.

Das EAS besteht dabei aus drei wesentlichen Komponenten. Dem Systemverhalten $\hat{y}$, der Berechnung optimierter Startwerte (BoS) und die Kompensation nicht-messbarer Einflussgrößen (KnE). Das Systemverhalten $\hat{y}$ gliedert sich wiederum in ein Stellgrößen- $\hat{y}_k$ und ein Störgrößenmodell $\hat{y}_{nk}$, die zusammen eine Prädiktion der Produktqualität berechnen. Ersteres nutzt gezielt kontrollierbare Einflussgrößen, um deren Auswirkungen auf die Produktmerkmale $\hat{y}_k$ abzubilden. Letzteres bildet die nicht-kontrollierbaren, aber messbaren Störgrößen x_{nk} in Kombination mit den aktuellen Stellgrößen x_k auf eine Pro-




Bild 3-11: Referenzarchitektur des EAS

duktmerkmalsabweichung $\Delta\hat{\mathbf{y}}_{nk}$ ab. So gilt für das Systemverhalten

$$\hat{\mathbf{y}}(\mathbf{x}_k, \mathbf{x}_{nk}) = \hat{\mathbf{y}}_k(\mathbf{x}_k) + \Delta\hat{\mathbf{y}}_{nk}(\mathbf{x}_k, \mathbf{x}_{nk}) \quad (3-1)$$

wenn angenommen werden kann, dass keine signifikanten Wechselwirkungen zwischen kontrollierbaren und nicht-kontrollierbaren Einflüssen vorliegen. In der Referenzarchitektur wurden Stellgrößen- und Störgrößenmodelle separiert, um eine frühzeitige Nutzung des EAS zu ermöglichen, ohne alle Einflüsse, insbesondere die nicht-kontrollierbaren und deren Auswirkungen kennen zu müssen. Die Auswirkungen der Stellgrößen sind in der Regel bekannt oder durch Versuche ermittelbar, sodass dieses bereits beim initialen Produktionsstart genutzt werden kann. Die nicht kontrollierbaren Störungen hingegen hängen maßgeblich von der Umgebung ab und lassen sich nicht gezielt ermitteln. Daher steht das Modell erst ab einer gewissen Produktionszeit zur Verfügung, in der die Störeinflüsse gemäß ihrer Varianz auf das System eingewirkt haben.

Das abgelegte Systemverhalten $\hat{\mathbf{y}}$ wird in den beiden Modulen (BoS, KnE) genutzt, um an die momentane Situation angepasste Handlungsvorschläge für den Maschinenbediener bereitzustellen. Beide Module setzen auf eine numerische Optimierung, um die Handlungsvorschläge zu berechnen. Der erste Schritt ist die BoS, die dazu dient Anfangswerte für das Einrichten zu berechnen. Während bei der Berechnung optimierter Startwerte noch keine aktuellen Qualitätsmerkmale zur Verfügung stehen, können diese Qualitätsmerkmale anschließend zur Kompensation der nicht-messbaren Störungen genutzt und somit die Produktqualität in einer weiteren Iteration verbessert werden. In dieser können die oben angesprochenen Wechselwirkungen und nicht-messbaren Einflüsse kompensiert werden.

In den nächsten Abschnitten (3.3.1 bis 3.3.4) werden nun die vier wesentlichen Module und deren Zusammenspiel näher erläutert und anschließend in einer Vorgehensweise eingeordnet. Anschließend wird im Kapitel 4 die Referenzarchitektur auf einen Beispielprozess angewendet und validiert.

3.3.1 Stellgrößenmodelle

Die Stellgrößenmodelle bilden in der Referenzarchitektur die wesentlichen, kontrollierbaren Einflüsse auf die Produkt- und Qualitätsmerkmale ab, bei konstanten weiteren Einflüssen:

$$\hat{\mathbf{y}}_k = \hat{\mathbf{y}}_k(\mathbf{x}_k) \quad (3-2)$$

Da das Stellgrößenmodell, wie das Störgrößenmodell, in einer Optimierung genutzt wird, ergeben sich zwei wesentliche Anforderungen an die Modelle. Zum einen müssen die Modelle die Produktqualität hinreichend genau abbilden und zum anderen recheneffizient sein, da sie in der Optimierung mehrfach mit unterschiedlichen Einflussgrößen ausgeführt werden, um die Präsiktion zu berechnen. Das bedeutet ebenfalls, dass die meisten physikalischen Modelle, die zur Simulation von Produktionsprozessen genutzt werden, nicht direkt zur Anwendung kommen können, da Rechenzeiten von mehreren Minuten bis Stunden oder Tagen in diesem Anwendungsszenario nicht zielführend sind. Regressionsmodelle (siehe Abschnitt 2.4) bieten die Möglichkeit eine ausreichend hohe Präzision bei einer sehr geringen Ausführungszeit zu kombinieren. Hierbei können für die Datengenerierung zwei unterschiedliche Quellen genutzt werden: Simulationen und empirische Versuche.

Zum einen können die bereits angesprochenen vorhandenen physikalischen Modelle genutzt werden. So können Mehrkörper- oder auch FE-Modelle in Kombination mit einem statistischen Versuchsplan genutzt werden, um mithilfe von Regressionsmodellen die wesentlichen Zusammenhänge für die Produktqualität zu berechnen. In dieser Variante werden die variablen Einflussgrößen simulativ variiert, um die resultierenden Auswirkungen zu berechnen. Der Vorteil an dieser RSM mit solchen dynamischen Modellen ist, dass hier nur das stationäre Ein-/ Ausgangsverhalten abgeleitet wird – eine Integration von Differenzialgleichungen ist nicht mehr notwendig und somit für die spätere Anwendung recheneffizienter. Weiterhin ist diese Methode, bei vorhandenen Simulationsmodellen, sehr kostengünstig und sicher, da auch bei einer Exploration der Prozessgrenzen kein Schaden am Werkzeug oder Prozess entstehen kann.

Eine weitere Quelle für Daten können empirische Versuche mit den Produktionsprozessen sein, die ebenfalls mithilfe des DoE geplant und durchgeführt werden. Hierbei ist es notwendig, dass die kontrollierbaren Einflüsse, wie zum Beispiel Prozessparameter, verändert werden. Weiterhin entsteht durch die Versuche, je nach Versuchsplan und Anzahl der betrachteten Einflussgrößen, ein erhöhter Kostenaufwand. Hierbei ist das benötigte Personal, die Maschinenzeit, die Betriebsmittel und Werkstoffe von Bedeutung. Der Kostenaufwand wird zusätzlich durch den notwendigen Stichprobenumfang zur Ermittlung eines Qualitätsmerkmals erhöht. Die notwendige Produktanzahl hängt von der Varianz der ermittelten Qualitätsmerkmale und der notwendigen Genauigkeit ab, um den Mittelwert der Qualitätsmerkmale hinreichend genau bestimmen zu können [Mon13, S. 51]. Aus diesen Gründen ist eine deutlich genauere Planung der Versuchsreihen im Gegensatz zur Simulation erforderlich.

Unabhängig von der Datenquelle (Simulationen oder empirische Versuche) entstehen Regressionsmodelle, die das Ein-/ Ausgangsverhalten beschreiben. Hierbei gilt es nun, nur die statistisch signifikanten Einflüsse zu berücksichtigen. Um die Signifikanz zu berech-

nen, wird eine ANOVA (siehe Abschnitt 2.4) durchgeführt: ein Overfitting des Modells, also ein zu starkes Anpassen an die Prozessvarianz, wird vermieden.

3.3.2 Störgrößenmodelle

Im vorherigen Abschnitt wurde dargelegt, dass die Stellgrößenmodelle über eine systematische Vorgehensweise wie der statistischen Versuchsplanung erstellt werden können. Dies gilt nicht für die Störgrößenmodelle

$$\hat{\mathbf{y}}_{nk} = \hat{\mathbf{y}}_{nk}(\mathbf{x}_k, \mathbf{x}_{nk}),$$

also die Abbildung der Auswirkungen nicht-kontrollierbarer Einflüsse auf die Produktmerkmale. Für die statistische Versuchsplanung (Design of Experiments) (SVP) ist es erforderlich diese Faktoren systematisch variieren zu können.

Um die Störauswirkungen abbilden zu können, kann das Expertenwissen mithilfe von physikalischen Modellen und anschließenden Simulationen genutzt werden. Die Modellierungsart wird hier bedarfsgerecht je nach betrachteten nicht-kontrollierbaren Einflüssen und Qualitätsmerkmalen ausgewählt. So werden für die Analyse von Vibrationen andere Modellarten genutzt, als für die Analyse von Materialänderungen. Die Modelle müssen validiert werden, um nicht nur eine qualitative, sondern eine quantitative Aussage zu ermöglichen. Hierfür müssen die entsprechenden Messungen mit dem System durchgeführt werden oder die Modellaussagen durch Experten bestätigt werden.

Eine weitere Möglichkeit ist die kontinuierliche Datenerfassung der wesentlichen Prozesseinflüsse und deren Auswirkungen auf die Qualitätsmerkmale. Insbesondere aufgrund günstiger Speichersysteme und dem Trend zur Vernetzung der Maschinen sind viele Prozesse bereits mit vielfältigen Sensoren für die Prozessüberwachung ausgestattet. Diese Daten können anschließend mit den Qualitätsdaten korreliert werden, um die Auswirkungen der Störgrößen zu ermitteln. Je nach Prozess und Taktzeit fällt hier ein großes Datenvolumen an, welches verarbeitet und analysiert werden muss. Da in dem hier betrachteten Fall die Qualitätsdaten vorhanden sein müssen, können die Algorithmen des überwachten Lernens zur Regression oder ggf. Klassifikation angewendet werden (siehe Abschnitt 2.4). Das Ergebnis ist die Abbildung der Störgrößen auf die absoluten Qualitätsmerkmale.

Zur Integration dieser absoluten Qualitätsmerkmale in die Referenzarchitektur werden diese nun in Relation zu dem bekannten Zustand des Stellgrößenmodells gesetzt. Somit beschreibt

$$\Delta \hat{\mathbf{y}}_{nk}(\mathbf{x}_k, \mathbf{x}_{nk}) = \hat{\mathbf{y}}(\mathbf{x}_k, \mathbf{x}_{nk}) - \hat{\mathbf{y}}_k(\mathbf{x}_k)$$

die Abweichung des Störverhaltens vom Maschinenverhalten und wird aus Gleichung (3-1) für die Beschreibung des Gesamtsystemverhaltens ersichtlich.

Mit der Aufteilung der Modelle in Stell- und Störgrößenmodelle wird ein Kompromiss zwischen Entwicklungszeit und Vorhersagepräzision gemacht. So kann das EAS bereits mit wenig Aufwand genutzt werden und zum Beispiel über kontinuierliche Messungen der Störgrößen über den Prozesslebenszyklus immer weiter verbessert werden. Die Stellgrößenmodelle werden hierbei als das Referenzverhalten betrachtet und die Störgrößenmodelle als Abweichung von diesem Verhalten integriert.




Bild 3-12: Toleranzbreite und Nominalwert

3.3.3 Berechnung der Startwerte

Beim Einrichten ist eine Herausforderung für den Maschinenbediener zunächst einen funktionsfähigen Parametersatz für den Prozess zu finden. Ideal wäre eine Invertierung des Systemverhaltens, um die für die angestrebten Qualitätsmerkmale benötigten Größen der kontrollierbaren Einflüsse direkt aus Gleichung (3-2) zu berechnen:

$$\mathbf{x}_k = \hat{\mathbf{y}}_k^{-1}.$$

Das Finden dieser Umkehrfunktion ist im Allgemeinen durch die unterschiedlichen Modelle nicht möglich und würde somit für jeden weiteren Prozess zusätzlichen Aufwand bedeuten. Daher wird in der hier vorliegenden Referenzarchitektur hierfür eine gradientenfreie numerische Optimierung genutzt, um optimierte Startwerte für den Maschinenbediener zu finden. Für den Erfolg der Optimierung ist die Definition der Zielfunktion von zentraler Bedeutung. Im Allgemeinen liegt dem hier vorliegenden Problem ein Mehrzieloptimierungsproblem vor, da eine Vielzahl unterschiedlicher Qualitätsmerkmale berücksichtigt werden muss. Durch die beschriebenen Wechselwirkungen der unterschiedlichen Stellgrößen auf die Qualitätsmerkmale werden die produzierten Merkmale nur in seltenen Fällen vollständig mit den Nominalwerten übereinstimmen: in der Regel wird ein Kompromiss bei den Einstellungen gesucht. In dem hier vorgeschlagenen Ansatz wird mithilfe einer gewichteten Summe die Komplexität des Optimierungsproblems auf eine Dimension reduziert.

Aufgrund des generalistischen Anspruchs des EAS ist eine einfache, aber auf die Qualitätsmerkmale abgestimmte Zielfunktion zu definieren. Hierbei wird berücksichtigt, dass sich sowohl Qualitätsmerkmale aus dem Prozess, als auch spätere Produktmerkmale stets innerhalb einer definierten Toleranz befinden müssen. So ergibt sich die Zielfunktion

$$\begin{aligned} J_s(\mathbf{x}_k) &= \sum_{i=1}^{n_y} \left(\frac{\hat{y}_i(\mathbf{x}_k, \mathbf{x}_{nk}) - y_{n,i}}{\Delta T_i} \right)^2 \\ &= \left\| \Delta \mathbf{T}^{-1} (\hat{\mathbf{y}} - \mathbf{y}_n) \right\|^2. \end{aligned} \quad (3-3)$$

In der Zielfunktion wird die gewichtete Abweichung des Systemverhaltens vom Nominalwert berechnet und aufsummiert. Hierfür wird die quadratische Abweichung des i -ten Elements $\hat{y}_i(\mathbf{x}_k, \mathbf{x}_{nk})$ von dessen Nominalwert $y_{n,i}$ (siehe 3-12) berechnet und mithilfe der

zugehörigen Toleranzbreite ΔT_i gewichtet (siehe 3-12). Die Summe wird über alle n_y Produktmerkmale durchgeführt. Äquivalent zu dem Ausdruck ist die quadrierte euklidische Norm der Multiplikation der invertierten Toleranzmatrix $\Delta \mathbf{T}^{-1}$ multipliziert mit dem Differenzvektor $\hat{\mathbf{y}} - \mathbf{y}_n$. Die Toleranzmatrix

$$\Delta \mathbf{T} = \begin{bmatrix} \Delta T_1 & & 0 \\ & \ddots & \\ 0 & & \Delta T_{n_y} \end{bmatrix}$$

ist mit den Toleranzwerten diagonal besetzt, sodass für die Invertierung

$$\Delta \mathbf{T}^{-1} = \begin{bmatrix} \frac{1}{\Delta T_1} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{\Delta T_{n_y}} \end{bmatrix}$$

gilt. Durch die individuelle Gewichtung mit der Toleranzbreite erfolgt eine bedarfsgerechte Priorisierung der Qualitätsmerkmale. So wird eine Abweichung eines strenger tolerierten funktionsgebenden Merkmals in der späteren Optimierung stärker gewichtet als ein Merkmal mit größerer Toleranz. Grundlage hierfür sind die von Produkt- und Produktionsprozessentwicklern festgelegten Grenzwerte. Das nichtlineare Optimierungsproblem

$$\begin{aligned} & \min_{\mathbf{x}_k \in \mathbb{R}^{n_v}} J_s(\mathbf{x}_k) \\ & \text{mit } \mathbf{x}_{k,u} \leq \mathbf{x}_k \leq \mathbf{x}_{k,o} \end{aligned}$$

wird unter der Begrenzung von $\mathbf{x}_k$ optimiert, da die vorhandenen Stelleingänge in der Regel eine physikalische Begrenzung aufweisen, um den Prozess nicht zu gefährden. Dies können zum Beispiel bei Softwareparametern maximal zulässige Temperaturen, bei Aktoren zulässige Verfahrwege oder Anschläge bei mechanischen Justagestellen sein.

Das Ergebnis der Optimierung sind die optimierten Startwerte für die kontrollierbaren Prozesseinflüsse $\mathbf{x}_{k,opt}$. Die Präzision dieser ist abhängig von der Qualität der Modelle, die für das Maschinen- und Störverhalten ermittelt wurden, sowie von den Toleranzen für die einzelnen Qualitätsmerkmale. Unter der Randbedingung genauer Modelle, sowie kaum vorhandener nicht-messbarer Einflussgrößen, wird diese Optimierung für eine optimale Parametrierung des Prozesses ausreichen. Wie bereits in Abschnitt 3.3.2 beschrieben, können die Störgrößenmodelle in der Regel nicht vor der ersten Produktion erstellt werden. Weiterhin existieren viele Prozesse, die durch nicht-messbare Störgrößen beeinflusst werden. Daher muss in vielen Fällen noch eine Kompensationsstrategie anhand der aktuellen Situation gefunden werden. Diese wird im nächsten Abschnitt 3.3.4 beschrieben.

3.3.4 Kompensation der Störungen

Die Kompensationsstrategie dient der Verbesserung der Produktqualität nach dem die optimierten Startwerte auf den Prozess angewendet wurden. Dies kann sowohl während des initialen Einrichtens der Anlage, als auch während des Betriebs erfolgen. Aufgrund von Modellungenauigkeiten und Störungen resultiert eine suboptimale Produktqualität, die in




Bild 3-13: Prinzipbild der Strategie zur Kompensation nicht-messbarer Einflussgrößen

einer anschließenden Iterationsphase verbessert wird. Grundlage sind nun eine ausreichend hohe Anzahl gefertigter Produkte, deren Qualitätsmerkmale ermittelt wurden.

Die Kompensationsstrategie ist in Abbildung 3-13 zu sehen. Wie beschrieben werden die optimierten Startparameter $\mathbf{x}_{k,opt}$ eingestellt und anschließend eine ausreichende Produktanzahl gefertigt, um den Erwartungswert mit erforderlicher Präzision berechnen zu können. Ein Ansatz hierfür wird über die Prozessfähigkeit geliefert.




Bild 3-14: Illustration der Kenngrößen des Prozessfähigkeitsindex

Diese beschreibt das Verhältnis der vorgegebenen Toleranz zur Prozessstreuung und charakterisiert die Lage des Mittelwerts zur vorgegebenen Toleranzmitte (siehe Abbildung 3-14). Der C_{pK} -Wert (Gleichung 3-4) steht damit in direkter Beziehung zur Prozessstreuung und berechnet sich aus dem Minimum der Abweichung des Stichprobenmittels μ von den Toleranzgrenzen y_u und y_o und ist antiproportional zur Standardabweichung σ :

$$C_{pK} = \frac{\min(\mu - y_u, y_o - \mu)}{3\sigma} \quad (3-4)$$

Damit kann aus dem C_{pK} -Wert auf die vorhandene Prozessstreuung geschlossen werden, welche ebenfalls für eine Abschätzung der notwendigen Stichprobe pro Einzelversuch benötigt wird. Bei einem bekannten C_{pK} -Wert gilt damit als Abschätzung für die Standardabweichung σ des Prozesses und die Qualitätsmerkmale:

$$\sigma = \frac{\min(\mu - y_u, y_o - \mu)}{3 \cdot C_{pK}}.$$

Die Varianz ist die Grundlage zur Abschätzung der Stichprobengröße n nach [Mon13, S. 51], sodass

$$n \geq \frac{z_{\alpha/2}^2 \cdot \sigma^2}{e^2}, \text{ mit der Transformation } z = \frac{y - \mu}{\sigma}$$

gilt. Die Stichprobengröße n wird in Abhängigkeit der Varianz σ^2 , dem erlaubten Fehler e und der standardisierten Zufallsvariablen der Normalverteilung für das benötigte Konfidenzintervall ermittelt.




Bild 3-15: Illustration der Berechnungsmöglichkeiten für das beidseitige Konfidenzintervall

Für ein beispielhaftes beidseitiges 95%-Konfidenzintervall beträgt $z_{\alpha/2} = \pm 1.96$. Hierfür wird das Integral über die Standardnormalverteilung (siehe Abbildung 3-15), links):

$$\Phi(-z_{\alpha/2}, z_{\alpha/2}) = 0.95 = \int_{-z_{\alpha/2}}^{z_{\alpha/2}} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du$$

gelöst [Mon13, S. 684]. Für eine Approximation stehen ebenfalls vorberechnete Tabellen zur Interpolation zur Verfügung (siehe A0-1). Daher werden häufig die Integrale von $-\infty$ bis zum interessierenden z -Wert betrachtet (siehe Abbildung 3-15, mittig und rechts). Somit werden die Integrale

$$\begin{aligned} \Phi(-z_{\alpha/2}) &= 0.025 = \int_{-\infty}^{-z_{\alpha/2}} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du \\ \Phi(z_{\alpha/2}) &= 0.975 = \int_{-\infty}^{z_{\alpha/2}} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du. \end{aligned}$$

gelöst und der oben genannte z -Wert ermittelt. Das Resultat ist die abgeschätzte Stichprobe für die Produkte.

Von diesen Produkten werden anschließend die gemessenen Qualitätsmerkmale $\mathbf{y}_m$ ermittelt und die Abweichung $\Delta \mathbf{y}_m$ zu den Nominalwerten $\mathbf{y}_n$ bestimmt. In dieser Abweichung sind implizit die Informationen zu den nicht-messbaren Einflussgrößen enthalten. Die Abweichungen vom Normverhalten werden für die Modifikation des Stell- und Störgrößenmodells genutzt. Dieses wird über einen Offset an die momentanen Umgebungsbedingungen angepasst:

$$\begin{aligned} \hat{\mathbf{y}}_c(\mathbf{x}_k, \mathbf{x}_{nk}) &= \hat{\mathbf{y}}_k(\mathbf{x}_k) + \Delta \hat{\mathbf{y}}_{nk}(\mathbf{x}_k, \mathbf{x}_{nk}) + \Delta \mathbf{y}_m \\ &= \hat{\mathbf{y}}(\mathbf{x}_k, \mathbf{x}_{nk}) + \Delta \mathbf{y}_m. \end{aligned}$$

Das Kompensationsmodell $\hat{\mathbf{y}}_c$ ergibt sich demnach aus den Anteilen der Stell- ($\hat{\mathbf{y}}_k(\mathbf{x}_k)$) und Störgrößenmodelle ($\Delta\hat{\mathbf{y}}_{nk}(\mathbf{x}_k, \mathbf{x}_{nk})$), sowie der ermittelten Abweichung der Qualitätsmerkmale ($\Delta\mathbf{y}_m$). Resultierend daraus ergibt sich eine Anpassung der Zielfunktion

$$\begin{aligned} J_c(\mathbf{x}_k) &= \sum_{i=1}^{n_y} \left(\frac{\hat{y}_i(\mathbf{x}_k, \mathbf{x}_{nk}) + \Delta y_{m,i} - y_{n,i}}{\Delta T_i} \right)^2 \\ &= \|\Delta\mathbf{T}^{-1}(\hat{\mathbf{y}} + \Delta\mathbf{y}_m - \mathbf{y}_n)\|^2, \end{aligned} \quad (3-5)$$

welche wiederum in ein Optimierungsproblem

$$\min_{\mathbf{x}_k \in \mathbb{R}^{n_y}} J_c(\mathbf{x}_k) \text{ mit } \mathbf{x}_{k,u} \leq \mathbf{x}_k \leq \mathbf{x}_{k,o}$$

integriert wird. Als Lösung resultiert der Einflussgrößenvektor $\mathbf{x}_c$, der die nicht-messbaren Störungen des Prozesses bei der Parametrisierung berücksichtigt. In einigen Prozessen ist die relative Abweichung zu den optimierten Startwerten $\Delta\mathbf{x}$ von Interesse, für die

$$\Delta\mathbf{x} = \mathbf{x}_c - \mathbf{x}_{k,opt}$$

gilt. Durch eine iterative Ausführung der Kompensationsstrategie, also der Produktion neuer Bauteile, dem Lösen des Optimierungsproblems und der Neujustage des Prozesses, kann so die Produktqualität iterativ und systematisch optimiert werden. Die Grenzen sind hierbei durch die Präzision der Parametrisierung, sowie der Ermittlung der Qualitätsmerkmale gesetzt.

3.4 Vorgehensweise

Damit ein Einrichtassistentensystem für einen Zielprozess entwickelt werden kann, wird im Folgenden die notwendige Vorgehensweise vorgestellt. Sie gliedert sich wie in Abbildung 3-16 in eine Analysephase, der Synthese der Stellgrößenmodelle, einer ersten Produktionsphase und der Synthese der Störgrößenmodelle.

Die Analysephase legt den Grundstein für die weitere Entwicklung des EAS. Ziel dieser Phase ist der Aufbau eines Prozessverständnisses, die Identifikation der wesentlichen Einflussgrößen und der Qualitätsmerkmale des Systems. Im ersten Schritt wird daher das Produkt hinsichtlich der vorhandenen Qualitätsmerkmale untersucht und diese bezüglich ihrer Signifikanz für das Produkt priorisiert. Es gibt in der Regel für Produkte funktionsgebende Eigenschaften, deren definierte Ausprägung von hoher Relevanz ist. Demgegenüber stehen Eigenschaften, die zur Ausgestaltung des Produktes definiert sein müssen, aber keine besondere Relevanz für dieses besitzen. Zusätzlich wird die Messbarkeit jedes Merkmals bewertet und eine ggf. notwendige Erweiterung des Sensorkonzepts des Produktionsprozesses initiiert.

Im nächsten Schritt werden zum Beispiel mit einem Ishikawa-Diagramm, zum Teil auch Fishbone-Diagramm genannt, die wesentlichen Einflüsse auf die Produktqualität mithilfe von Prozessexperten identifiziert und bezüglich ihrer Kontrollier- und Messbarkeit strukturiert. Einflüsse können hier mithilfe der 5M-Methode systematisch erfasst werden und verschiedener Natur sein. Um relevante Einflussgrößen für die bereits identifizierten Qualitätsmerkmale zu finden, können diese in einer Matrix gegenübergestellt und bezüglich




Bild 3-16: Darstellung der Vorgehensweise für das EAS

der vermuteten Einflussnahme auf das jeweilige Qualitätsmerkmal bewertet werden. So können weitere Qualitätsmerkmale oder auch Einflussgrößen für die weitere Untersuchung ausgeschlossen werden. Das Ziel ist hierbei die wichtigsten Qualitätsmerkmale und Einflussgrößen zu identifizieren, um eine wirtschaftliche Umsetzung zu gewährleisten.

Im nächsten Schritt der Analysephase werden Vorversuche mit den Stellgrößen durchgeführt. Zunächst wird mithilfe erster Messungen die Fähigkeit der Sensorsysteme sichergestellt und die Prozessstreuung analysiert. Wenn der Prozess stabil ist und die Prozessfähigkeit den Erwartungen entspricht, werden die Vorversuche durchgeführt. Hierfür wird ein teilfaktorieller Versuchsplan genutzt, um ein Regressionsmodell erster Ordnung zu berechnen. Dieses wird mithilfe zusätzlicher Versuche validiert. Für dieses werden mithilfe der ANOVA die signifikanten Einflüsse ermittelt. Das heißt, es werden Einflüsse ermittelt, die von der weiteren Betrachtung ausgeschlossen werden. So wird eine wirtschaftliche Modellsynthese sichergestellt.

Der nächste Schritt der Vorgehensweise ist die Synthese des Stellgrößenmodells. Hierfür wird zunächst ein Versuchsplan für die identifizierten Stellgrößen ausgewählt. Kriterien hierfür sind die Anzahl der Stellgrößen, die Anzahl der zulässigen Versuche und die Ausprägung des mutmaßlichen Ein-/ Ausgangsverhaltens. Wie in Abschnitt 2.4 beschrieben, stehen hierfür Versuchspläne mit unterschiedlichen Eigenschaften zur Verfügung. Nach der Auswahl des Versuchsplans werden, unter Berücksichtigung der Prinzipien der statistischen Versuchsplanung, die Versuche durchgeführt. Nach der Regressionsanalyse können mithilfe von Residuenplots die Plausibilität der Versuchsdaten und Modelle untersucht und ggf. Ausreißer identifiziert werden. Bei den Residuenplots werden die gemessenen Werte gegenüber den prädictierten Werten aufgetragen (zum Beispiel [TNW⁺16]), um eine Abweichung von der Winkelhalbierenden der beiden Achsen zu identifizieren. Eine Alternative ist die der Größe nach sortierten Residuen gegenüber der Auftretenswahrscheinlichkeit (zum Beispiel [Mon13, S. 81]) aufzutragen. In Kombination mit der ANOVA wird ein generalisierendes Modell erstellt, welches die Qualitätsmerkmale mithilfe der Stellgrößen prädictiert. Abschließend wird das Modell mithilfe zusätzlicher Versuche validiert. Aufgrund falscher Annahmen kann für diese Phase ein iteratives Vorgehen notwendig sein, da Versuchsplan, Versuche und Modell variiert werden müssen. Das Er-

gebnis ist das Stellgrößenmodell, welches in Kombination mit der Berechnung optimierter Startwerte und der Kompensation nicht-messbarer Störungen genutzt werden kann. Bereits ab diese Phase können die Maschinenbediener beim Einrichten des Zielsystems unterstützt werden.

In der nächsten Phase unterstützt das System den Produktionsbetrieb. Während dieser Phase wird das System für das Einrichten genutzt und die identifizierten messbaren Störgrößen, sowie die resultierenden Qualitätsmerkmale aufgezeichnet. Diese Phase wird solange fortgeführt bis die Störgrößen aufgrund ihrer Varianz den erwarteten Bereich abgedeckt haben. Aufgrund der stetigen Produktwechsel in der Produktion kann diese Phase längere Zeit in Anspruch nehmen.

Sobald die Produktionsdaten zur Verfügung stehen, startet die letzte Phase zur Entwicklung des EAS. In dieser Phase werden die Produktionsdaten genutzt, um das Störgrößenmodell zu erstellen. Hierfür werden Regressionsverfahren aus dem Bereich des maschinellen Lernens genutzt, um die relativen Auswirkungen der Störgrößen auf die Qualitätsmerkmale zu approximieren. Da eine Voraussage eines geeigneten Algorithmus nicht möglich ist, werden verschiedene ML-Algorithmen trainiert und hinsichtlich ihrer Prädiktionsgenauigkeit verglichen. Das Ergebnis ist das Störgrößenmodell, welches ab diesem Zeitpunkt das Einrichtassistentensystem unterstützt und die Einrichtqualität und -effizienz durch ein genaueres Modell steigert. Dies stellt einen optionalen Schritt dar, der sich insbesondere für kostenintensive Bauteile rentiert.

3.5 Bewertung der Anforderungserfüllung

Im Folgenden wird die Systematik bezüglich der Erfüllung der sieben in Kapitel 3.2 identifizierten Hauptanforderungen überprüft mithilfe einer qualitativen Experteneinschätzung. Das Ergebnis ist in dem Netzdiagramm in Abbildung 3-17 illustriert und zusammengefasst. Wenn eine Anforderung mit Stufe 1 bewertet wird, ist das gleichbedeutend mit einer Nichterfüllung der Anforderungen. Stufe 5 heißt hingegen, dass die Anforderung vollständig erfüllt wird.

Übertragbarkeit

Die Anforderung nach einer einfachen Übertragbarkeit auf weitere Prozesse wurde durch die Auswahl der vorgeschlagenen Methoden sichergestellt. So wird die Response-Surface Methode als effizientes statistisches Verfahren eingesetzt, um die Stellgrößenmodelle zu entwickeln. Die Datengrundlage können hier sowohl vorhandene, detaillierte physikalische Modelle, als auch die reale Anlage mithilfe von Experimenten liefern. Dies ist wichtig, da einige Prozesse hochkomplexe oder -dynamische Vorgänge beinhalten, deren Modellierung einen nicht unerheblichen Aufwand impliziert. Aufgrund der Möglichkeit die notwendigen Daten (teil-) automatisiert zu generieren und zu verarbeiten, können weitere Prozesse mit geringem Aufwand erschlossen werden. In der Systemarchitektur sind Störgrößenmodelle als Option vorgesehen, was zusätzlich die Flexibilität steigert. Auch wenn Störungen nicht vollständig erfasst werden können (da sie zum Beispiel messtechnisch nicht wirtschaftlich erfassbar sind), kann das System trotzdem auf solche Systeme übertragen werden. Diese Anforderung wird daher als vollständig erfüllt (Stufe 5) bewertet.

Flexibilität




Bild 3-17: Bewertung der zusammengefassten Anforderungen im Netzdiagramm

Aufgrund der Wahl abstrahierter Schnittstellen ist eine Nutzung mit unterschiedlich automatisierten Prozessen möglich. Generell ist sowohl eine automatisierte Zuführung der Eingangsdaten zum EAS, als auch eine manuelle Eingabe realisierbar. Auch die Handlungsempfehlungen des EAS können in beiden Varianten verarbeitet werden. Je nach Anwendung ist bei der Ausarbeitung der Schnittstellen demnach noch Aufwand vorhanden, da diese aufbereitet und zugänglich gemacht werden müssen. Allerdings ist der Kern der Architektur davon nicht betroffen, dieser ist flexibel einsetzbar. Aufgrund der notwendigen weiteren Anpassungen der Schnittstellen wird die Anforderung als gut erfüllt (Stufe 4) kategorisiert.

Bedienbarkeit

Durch die Trennung der Modellbildung von der späteren Anwendung in der Produktion, benötigt der Maschinenbediener keine spezifische Fachkenntnis von den eingesetzten Methoden. In der Entwicklung oder Erstinbetriebnahme des Prozesses wird der Maschinenbediener mit den vorgeschlagenen Methoden, wie der RSM, bei seiner Arbeit systematisch unterstützt, sodass gezielt die Funktionsfähigkeit nachgewiesen werden kann. Als Beiprodukt dieses Prozesses werden die Stellgrößenmodelle für den Einrichtungsassistenten entwickelt. Die eingesetzte Architektur könnte perspektivisch ebenfalls zentralisiert auf einem Server vorgehalten werden, sodass die notwendigen Informationen ortsunabhängig zur Verfügung stehen. Der Bediener wird allein mit den für ihn interessanten Informationen, wie den Einflussgrößen und den Qualitätsmerkmalen versorgt und kann diese dann für sich bewerten und an der Maschine nutzen. Aus diesem Grund wird diese Anforderung als vollständig erfüllt (Stufe 5) eingeordnet.

Konfigurierbarkeit

Zunächst ist die Entwicklung des EAS unabhängig von den prozessindividuellen Einfluss- und Zielgrößen. Allerdings muss berücksichtigt werden, dass bei einer wachsenden Anzahl von wechselwirkenden Einflussgrößen die Anzahl der notwendigen Experimente ebenfalls steigt – dies kann zeit- und kostenintensiv sein. Daher ist es bei einer größeren Anzahl an Einflussgrößen hilfreich das Zielsystem im Vorfeld genau zu analysieren,

um mögliche separate Betrachtungen der Einflüsse zu identifizieren. So können die notwendigen Versuche auf ein Minimum reduziert und kosteneffizient umgesetzt werden. Die Anforderung wird somit zum Großteil erfüllt, mit der Einschränkung eines höheren Aufwands bei höherer Prozesskomplexität bezüglich der Einflussgrößen. Diese Einschränkungen hinsichtlich der Systemkomplexität werden ebenfalls in der Bewertung der Anforderungserfüllung berücksichtigt, sodass bezüglich der Konfigurierbarkeit eine mittlere Erfüllung (Stufe 3) der Anforderung definiert wurde.

Robustheit

Die Robustheit des Systems gegenüber den üblichen Ungenauigkeiten in der (datenge-triebenen und physikalischen) Modellbildung wird durch den zweischrittigen Ansatz sichergestellt. Durch die Aufteilung auf eine Berechnung initialer Stellgrößen und einer anschließenden Kompensation, basierend auf den momentan vorherrschenden Qualitätsmerkmalen, werden die Auswirkungen von Modellungenauigkeiten kompensiert und die Modelle so an die realen Begebenheiten adaptiert. Durch das zweischrittige Vorgehen wird ein robustes Verhalten sichergestellt und damit die Anforderung vollständig erfüllt (Stufe 5).

Effizienz

Aufgrund der Aufteilung des Systemmodells in Stell- und Störgrößenmodell, kann bereits nach der Erstinbetriebnahme das System zum Einrichten genutzt werden. Das heißt, beim Produktionsstart können optimierte Stellgrößen berechnet und mithilfe der Kompensationsstrategie vorhandene Störungen eliminiert werden. Der Einrichtprozess wird dadurch reproduzierbar und die Qualität der Produkte sichergestellt. Die Anforderung wurde damit sehr gut erfüllt, allerdings steht dieser das gewählte iterative Vorgehen bei einem Einrichtvorgang entgegen, welcher somit zeitaufwändiger sein kann. Als Resultat wird die Anforderung als gut erfüllt (Stufe 4) kategorisiert.

Lernfähigkeit

Die Modellaufteilung erlaubt ebenfalls eine kontinuierliche Verbesserung des Systems, bei gleichzeitig schnellem Einsatz. So können während der ersten Phase, der Anwendung der Stellgrößenmodelle, Daten aus der digitalisierten Produktion gesammelt und mithilfe von ML-Verfahren in Störgrößenmodelle überführt werden. In der zweiten Phase können diese Modelle dann sowohl für eine genauere Präskription genutzt, als auch in den Entwicklungsprozess zurückgeführt werden. Durch die genauere quantitative Kenntnis der Störgrößen auf den Produktionsprozess können diese in den nächsten Iterationen weiter verbessert werden. Die Lernfähigkeit stellt somit eine wichtige Säule des EAS dar, kann allerdings erst bei ausreichender Datenlage sinnvoll angewendet werden. Aus diesem Grund wird die Anforderungserfüllung mit gut (Stufe 4) bewertet.

Fazit

In diesem Kapitel wurde zunächst eine Klassifikationssystematik für Einrichtassistentensysteme basierend auf dem Stand der Technik entwickelt. Hierbei wurden als wesentliche Kategorien das Unterstützungsziel, die -art und die technische Komplexität bezüglich Datenaufnahme, -verarbeitung und dem Systemeingriff identifiziert. Im Anschluss wurden die Rahmenbedingungen aus der Produktion, bezogen speziell auf das Einrichten von Produktionsanlagen, konkretisiert. Hierbei stellte sich heraus, dass das Einrichten in der heutigen Zeit immer noch hohe Relevanz besitzt,

aber durch die momentanen Entwicklungen und Trends komplexer wird und häufiger durchgeführt werden muss. Aus diesen Rahmenbedingungen und der Klassifikationssystematik konnten dann konkrete Anforderungen an das EAS abgeleitet und anschließend eine Referenzarchitektur für die Systematik, inklusive der notwendigen Funktionen entwickelt werden. Letztere beruhen auf einer zweischrittigen mathematischen Optimierung, die zunächst optimierte Startwerte berechnet und anschließend nicht messbare Störungen kompensiert. Die Optimierung basiert auf einer Zielfunktion mit einer toleranzbasiert gewichteten Summe.

Die Überprüfung der Anforderungserfüllung hat gezeigt, dass die entwickelte Systematik die Anforderungen im Allgemeinen sehr gut erfüllen. Die Analyse hat noch einmal hervorgehoben, dass die methodische Aufteilung von Stell- und Störgrößenmodellen vorteilhaft ist. So kann bereits zu Produktionsbeginn das EAS effizient angewendet werden. Auch wenn die Präskription aufgrund der fehlenden Daten zu den Störungen noch Ungenauigkeiten aufweisen wird, werden diese mithilfe der entwickelten Kompensationsstrategie eliminiert. Diese bietet weiterhin den Vorteil, dass momentan vorhandene, nicht-messbare Störungen durch die Berücksichtigung aktueller Qualitätsmerkmale ebenfalls durch den Algorithmus ausgeglichen werden. In der nächsten Phase können die nicht beeinflussbaren Störungen und die resultierenden Qualitätsmerkmale während der Produktion beobachtet werden. Diese Beobachtungen können dann für die Modellierung der Störungen genutzt werden. Somit wird die Lernfähigkeit des Systems sichergestellt.

Es hat sich gezeigt, dass die Systematik den identifizierten Anforderungen auf theoretischer Basis genügt. Um das konzipierte Vorgehen zu validieren, wird im nächsten Kapitel mithilfe der Systematik ein Einrichtassistenzsystem für einen exemplarischen Produktionsprozess entwickelt und erprobt. Mithilfe der Anwendung wird die Vollständigkeit der Systematik und die Leistungsfähigkeit der Algorithmen untersucht.

4 Validierung der Systematik für Einrichtassistentensysteme

In diesem Kapitel wird die in Kapitel 3 erarbeitete Systematik an einem Beispielprozess validiert. Der als Validierungsbeispiel betrachtete Prozess ist ein FVP, welcher spezifisch für die Produktion eines Bauteils der elektrischen Verbindungsindustrie genutzt wird (siehe Abbildung 4-1). Der Prozess wurde bereits in Betrieb genommen und für die Produktion der Bauteile erfolgreich genutzt.




Bild 4-1: Betrachteter Folgeverbundprozess mit Messstation

Gemäß dem im Abschnitt 3.4 dargestellten Vorgehen der Systematik, wird zunächst das FWZ näher beschrieben und analysiert, um die wesentlichen Ein- und Ausgänge für dieses System zu ermitteln und wesentlichen Produktmerkmale herauszuarbeiten. Anschließend werden Stell- und Störgrößenmodelle entwickelt, um das EAS auszu detaillieren. Die Algorithmen der Startwertberechnung und die Kompensationsstrategie mit dem Stellgrößenmodell werden an der realen Anlage validiert. Die in Abschnitt 3.3.2 vorgestellten Ansätze zur Integration von ML werden modellbasiert getestet. Hierfür wird ein Referenzmodell entwickelt und mithilfe physikalisch motivierter Störgrößenmodelle das noch hypothetische Szenario eines Werkzeugs mit sensorischer Überwachung der nicht-kontrollierbaren Einflussgrößen simuliert. Die resultierenden Ergebnisse werden diskutiert und abschließend bewertet.

4.1 Analyse des Folgeverbundwerkzeugs

Der Ablauf des betrachteten Folgeverbundprozesses (FVP) ist vereinfacht in Abbildung 4-2 dargestellt. Das Werkzeug besteht aus einem Ober- und einem Unterwerkzeug und wird in eine Schnellläuferpresse, eine Bruderer BSTA 500, für die Produktion eingebaut. Im Betrieb wird der obere Werkzeugteil in eine zyklisch-translatorische Bewegung versetzt, um über die Stanz- und Biegestempel das Material in das gewünschte Endprodukt




Bild 4-2: Prinzipschaubild des betrachteten FVWZ

zu verarbeiten. Als Halbzeug kommt ein Bandmaterial aus CuNi3SiMg zum Einsatz: eine niedriglegierte Kupferlegierung mit mittlerer Leitfähigkeit, hoher Festigkeit, guter Biegsbarkeit und sehr guter Relaxationbeständigkeit [Vin16, S. 551]. Mit jedem Hub der Schnellläuferpresse wird das Bandmaterial um einen definierten Weg über einen Vorschub weiter befördert. So durchläuft das Band Schritt für Schritt jede der Bearbeitungsoperationen bis am Ende des Werkzeugs das (vorläufige) Endprodukt zur Verfügung steht (siehe Abbildung 4-3). Das Endprodukt kann hierbei aus dem Trägermaterial ausgestanzt werden und so als separiertes Bauteil zur Verfügung stehen oder in dem Trägermaterial für ein vereinfachtes Handling verbleiben.




Bild 4-3: Das Produkt im Trägermaterial während der Qualitätsermittlung in der Messstation (Otto Vision Inspektionslösung von Jenoptik)

Die Stanz- und Biegestempel können dabei durch **Stellschrauben** an die momentane Störsituation angepasst werden. Die Stellschrauben aktuierten ein Keilschiebersystem, welches den Eingriffszeitpunkt und -ort selbiger variiert und so zum Beispiel ein definiertes Überbiegen bei Winkeln zur Kompensation der Rückfederung ermöglicht. Die adressierten **Störungen** können in diesem Prozess vielfältiger Natur sein: Neben den insbesondere herstellerübergreifend schwankenden Materialeigenschaften, wie Banddicke, Festigkeit oder Legierungszusammensetzung, ist auch der Werkzeugzustand von Bedeutung. Hier können sich zum Beispiel der momentane Verschleißgrad jedes einzelnen Stempels, der Schmierzustand des Werkzeugs, aber auch die Werkzeugtemperatur auf die Produktmerkmale auswirken.

Zusätzlich haben die **Maschinenparameter** einen Einfluss auf die Qualitätsmerkmale,

so wird durch die Massenträgheit bei höheren Produktionsgeschwindigkeiten das obere Werkzeug stärker verformt, was sich ebenfalls auf die Produkte auswirkt. Auch die eingestellte Kraft, mit der das Werkzeug belastet wird, kann die Qualität des Produkts positiv oder negativ beeinflussen. Wie zuvor angedeutet, wird das Halbzeug in diesem Fall in einem Reel-to-Reel Prozess verarbeitet, bei dem ein Bandmaterial von einem Coil zum anderen ab- und aufgewickelt wird. Dies ist vorteilhaft bei einer nachgelagerten Qualitätssicherung, die so auf eine definierte Positionierung der Bauteile zurückgreifen kann. Bei einigen Prozessen, wie der hier betrachtete, werden die resultierenden **Produktmerkmale** mit einer geeigneten Messtechnik erfasst und dienen so dem Bediener als Referenz für das Einrichten und der Qualitätssicherung.

Der betrachtete Folgeverbundprozess (FVP) ist als dreistufiges Verfahren ausgeführt, welches zwei unterschiedliche Produktvarianten fertigen kann. Sie unterscheiden sich im Wesentlichen durch eine geometrische Längenabweichung zwischen zwei funktionsgebenden Elementen. Die erste Stufe ist das Vorstanzen, welches in einer Taktzahl von 400 Hube pro Minute durchgeführt wird. In diesem Schritt wird das unbeschichtete Band gestanzt und in einem Kontaktbereich des Produkts vorgebogen, um eine spätere selektive Beschichtung zu ermöglichen und so den Kontakt für die spätere elektrische Verbindung zu verbessern. Für die unterschiedlichen Produktversionen wird ein Modul des Werkzeugs ausgetauscht. Abschließend wird das Band zusammen mit einem Trennmaterail aufgewickelt, um ungewollte Verformungen zu reduzieren. In der zweiten Stufe wird das Band zuerst verzinkt und anschließend selektiv beschichtet, um den Übergangswiderstand zu reduzieren.

Die letzte Stufe ist das Fertigstanzen, welches eine Taktzahl von 250 Hübem pro Minute erreicht. Dieses besteht aus zwei Werkzeugmodulen, aufgeteilt in Kontakt- und Schneidklemmmodul, welche das Produkt finalisieren. In diesem Schritt werden unterschiedliche Stanz- und Biegeoperationen sequentiell an dem Produkt vorgenommen, um die gewünschte Geometrie zu erhalten. Die Operationen finden in einem definierten Bereich oberhalb des unteren Totpunkts der Hubbewegung der Schnellläuferpresse statt. Im Falle einer Maßabweichung der funktionsgebenden Merkmale können über fünf Justagestellen im ersten Modul und vier Justagestellen im zweiten Modul (siehe Abbildung 4-1) die Biegeoperationen angepasst werden. Diese neun Stellschrauben beeinflussen den Stellweg des Biegestempels über ein Keilschiebersystem. Durch die unterschiedlichen Eingriffsmöglichkeiten werden jeweils andere Merkmale des Produkts beeinflusst.

4.1.1 Voruntersuchung Stellgrößenmodell

In Anlehnung an Abschnitt 3.4 wurde der Einfluss der Stellschrauben auf die Produktmerkmale in zwei Schritten ermittelt. Zunächst wurde zusammen mit dem Konstrukteur des Werkzeugs in einem Workshop der Einfluss jeder Stellschraube auf die Produktmerkmale abgeschätzt. Anschließend wurden Vorversuche durchgeführt, um einen signifikanten Einfluss der Stellschrauben auf diese Produktmerkmale nachzuweisen. Beide Schritte werden im Folgenden näher erläutert.

Im ersten Schritt wurde eine Übersichtsmatrix (siehe Abbildung 4-4) mithilfe eines Experteninterviews erstellt, die die laut Experten wahrscheinlichen Einflüsse der Stellschrauben (Justagen x_1 bis x_9) auf die jeweiligen Produktmerkmale (3 bis 66) veranschaulicht.



Bild 4-4: Einflüsse der Stellschrauben auf Produktmerkmale

Das Ziel dieser Visualisierung ist die Identifikation von Justagegruppen, die separat voneinander betrachtet werden können. So kann die notwendige Versuchsanzahl reduziert werden, da die Einflüsse auf verschiedene Qualitätsmerkmale separiert und Wechselwirkungen zwischen den Gruppen vernachlässigt werden können. Es zeigt sich, abgesehen vom Qualitätsmerkmal 30, dass die beiden Produktionsmodule bezüglich der beeinflussten Qualitätsmerkmale entkoppelt sind. Dies ist daran zu erkennen, dass in der Matrix die einzelnen Merkmale jeweils nur von den Justagestellen eines der Module beeinflusst werden. Daher können die beiden Produktionsmodule bei der Entwicklung des EAS separat betrachtet werden und demnach kann von einer deutlich reduzierten Versuchsanzahl profitiert werden, um die Auswirkungen der Stellschrauben zu erfassen. Im Folgenden wird die Systematik anhand des ersten Produktionsmoduls dargestellt. Für dieses Modul wurden zusätzlich die funktionsgebenden und damit für das EAS signifikanten Qualitätsmerkmale innerhalb des Workshops identifiziert.




Bild 4-5: Betrachtete Stellschrauben und identifizierte Einflüsse auf die signifikanten Qualitätsmerkmale

Wie in Abbildung 4-5 zusammenfassend dargestellt, werden nun fünf Stellschrauben und vier Qualitätsmerkmale, basierend auf den Produktmerkmalen, für diese Arbeit exemplarisch betrachtet (siehe Abbildung 4-6). Die ersten beiden Qualitätsmerkmale (y₁, y₂) sind Längen des Zielproduktes, die anderen beiden (y₃, y₄) Winkel. Die Auswahl ergibt sich aus den Kriterien der Messbarkeit der Qualitätsmerkmale und der Relevanz für die spätere Bauteilfunktion.

Um die signifikanten, kontrollierbaren Einflussgrößen zu ermitteln, werden Vorversuche durchgeführt. Für jedes Experiment wird eine hinreichend hohe Anzahl an Produkten




Bild 4-6: Abstrahierte Abbildung des Produkts und die vier identifizierten Qualitätsmerkmale

benötigt, um die Prozessstreuung bei der Bestimmung der Qualitätsmerkmale zu kompensieren. Für eine erste Abschätzung der Stichprobengröße kann auf die für den Prozess vorgegebene Prozessfähigkeit zurückgegriffen werden.

Da der betrachtete Folgeverbundprozess die Abnahme bestanden hat, kann angenommen werden, dass die Prozessfähigkeit des Folgeverbundprozesses bei korrekter Einrichtung erfüllt wird. Es wird zusätzlich vorausgesetzt, dass bei der Einrichtung allein die Mittelwertlage der Merkmale konfiguriert wird, die Streuung des Prozesses soll unverändert bleiben. Für die Merkmale existiert ein definierter C_{pK} -Wert. Für die tolerierten, ausgewählten Qualitätsmerkmale (y_1 und y_2) wurden die Toleranzen im strengsten Fall auf $\pm 0,1$ mm festgelegt und so mithilfe der in Abschnitt 3.3.4 vorgestellten Vorgehensweise die Stichprobengröße festgelegt.

Vorversuche zur erweiterten Systemanalyse

Durch die Abschätzung ist nun bekannt, welche Stichprobe benötigt wird, um eine hinreichend genaue Aussage für den Mittelwert eines jeden Einzelversuchs des Versuchsplans treffen zu können. Für die Voruntersuchung wurde ein teilfaktorieller Versuchsplan (siehe Anhang A0-2) genutzt, um die signifikanten Stellgrößen und ggf. Wechselwirkungen zu ermitteln. Hierzu wurde zunächst je Einflussgröße der Stellbereich ermittelt und dieser auf dimensionslose $\pm 0,5$ normiert. Als Referenzposition oder Nullposition für jede Stellschraube konnte ein mechanischer Anschlag der Aktorkinematik genutzt werden. Zusätzlich zu notwendigen Versuchen des teilfaktoriellen Versuchsplans wurden Validierungsversuche vorgesehen, bei denen jeweils nur eine Stellgröße von dem Zentralpunkt variiert wird. In Summe werden daher zusätzlich die Faktoreinstellungen des Zentralpunkts und eines Zwischenpunkts, wie in Abbildung 4-7 prinzipiell für einen zweidimensionalen Raum dargestellt, durchgeführt. Vor der Durchführung der Versuche wurde der Versuchsplan randomisiert, um systematische Fehler bei der Einstellung der Stellschrauben zu minimieren.

In Abbildung 4-8 sind die Messwerte eines Experiments der durchgeführten Vorversuche abgebildet. Je Einstellung wurden 200 Bauteile produziert und die als relevant identifizierten Qualitätsmerkmale y_1 bis y_4 ermittelt. Neben den Messungen in grün, ist der Toleranzbereich in grau hinterlegt und der Nominalwert mit einer Strichpunktlinie dargestellt. Es ist zu erkennen, dass sich bei diesen Messungen die Streubreite der Merkmale deutlich voneinander unterscheidet und zusätzlich die Lage der Qualitätsmerkmale differiert. So liegen die beiden Merkmale y_1 und y_2 auf den jeweils entgegengesetzten Toleranzgren-




Bild 4-7: Prinzipdarstellung der zur Validierung zusätzlich durchgeführten Vorversuche (in grün)

zen, Merkmal y_3 schwankt deutlich über dem Nominalwert innerhalb des Toleranzbereichs und Merkmal y_4 liegt außerhalb des unteren Toleranzbereichs. Da die abgebildete Messung eine Momentaufnahme aus dem Versuchsplan ist, ist eine Abweichung vom Toleranzbereich zufällig und auch gewünscht, um die Effekte der variablen Einflussgrößen auf die Qualitätsmerkmale ermitteln zu können.

Während die Versuche in Abbildung 4-8 ein hinreichend glattes Verhalten zeigen, ist während eines anderen Versuchs, wie in Abbildung 4-9 dargestellt, eine sehr hohe Streuung des Merkmals y_3 zu beobachten. Auch die weiteren Merkmale variieren deutlich innerhalb des Experiments. Aus diesen Messungen kann der Schluss gezogen werden, dass gewisse Einstellungen des Werkzeugs zu einer erhöhten Streuung des Prozesses führen. Die Ursachen wurden in einer weiteren, im Folgenden beschriebenen Analyse identifiziert.

In Abbildung 4-10 sind exemplarisch die Messergebnisse der normierten Einzelverstellung (Teil der Validierungsversuche) der Justagestelle x_4 zu sehen. In der Darstellung sind die Einzelversuche mithilfe von Boxplots aggregiert dargestellt. Jedes Experiment besteht, analog zu den vorherigen Abbildungen, aus 200 Messpunkten. Je Experiment wird ein Box-Plot erstellt, dessen orangener Balken den Median der Messpunkte angibt. Die Box selbst, in grün dargestellt, illustriert die 25%- und 75%-Perzentile der Messungen: die Höhe dieser Box wird Interquartilrange (IQR) genannt. Die Antennen, im Englischen als Whiskers bezeichnet, sind üblicherweise auf das 1.5-fache der IQR begrenzt. Alle Messpunkte, die außerhalb dieser Begrenzung liegen, werden zunächst mit einem roten Kreuz als Ausreißer definiert. Ob diese Punkte tatsächlich als Ausreißer gelten können, muss individuell analysiert werden: eine absolute Aussage ist mit dieser Methodik nicht möglich. Bei der Analyse der Messungen in der Abbildung 4-10 fällt die hohe Streuung fast aller Versuche auf und umfasst alle Merkmale in unterschiedlichen Ausprägungen. Zusätzlich zeigt sich der Haupteffekt der Justagestelle 4 auf die einzelnen Merkmale. Fast jedes Qualitätsmerkmal zeigt eine Änderung bei einer Verstellung der betrachteten Justagestelle. Zwischen den einzelnen Box-Plots sticht der Versuch bei -0.25 des normierten Verstellbereichs hervor. Diese Werkzeugeinstellung zeichnet sich durchgängig durch eine sehr geringe Streuung aus.

Diese Auswertung indiziert, dass eine Verstellung der Justagestelle x_4 zwar die Merkmale wesentlich beeinflusst, aber zusätzlich das Streuverhalten der Qualitätsmerkmale prägt. Aus diesem Grund wird die Justagestelle 4 für die Hauptversuche auf einen Wert fixiert, um eine konstant niedrige Streuung der Qualitätsmerkmale zu erreichen. Diese Erkenntnis




Bild 4-8: Beispielmessung der Vorversuche (grün) und der zugehörige Toleranzbereich (grau)




Bild 4-9: Weitere Beispielmessung der Vorversuche mit erhöhter Streuung (grün) mit zugehörigem Toleranzbereich (grau). Die Achsen sind zwecks Übersichtlichkeit unterschiedlich zu der vorherigen Abbildung skaliert.

wird dadurch gestützt, dass die in der letzten Produktion angewendete Einstellung der betrachteten Justagestelle nahezu identisch mit der hier gefundenen war. Ein zusätzlicher




Bild 4-10: Boxplots der Justagestelle 4 für die Einzelverstellungen

Vorteil für die Hauptversuche ist eine Reduktion der notwendigen Versuche aufgrund der Fixierung der Justagestelle.

Trotz der hohen Streuung einiger Messungen, wird nun die Signifikanz der Stellgrößen für die betrachteten Qualitätsmerkmale untersucht. Hierfür wird ein polynomiales Regressionsmodell erster Ordnung inklusive der ersten Wechselwirkungen

$$\begin{aligned}\hat{y}_i &= \beta_0 + \beta_1 x_1 + \dots + \beta_5 x_5 + \beta_{1,2} x_1 x_2 + \dots + \beta_{4,5} x_4 x_5 \\ &= \beta_0 + \sum_{i=1}^5 \beta_i x_i + \sum_{i=1}^4 \sum_{j=1}^5 \beta_{i,j} x_i x_j\end{aligned}$$

mithilfe der teilfaktoriellen Versuche berechnet und dessen Koeffizienten analysiert. Bei der Analyse der Residuen des Regressionsmodells zeigt sich, dass es eine Abweichung von der Normalverteilung der Residuen (siehe Abbildung 4-11) insbesondere an den Randbereichen gibt. Ein Residuum r_i ergibt sich aus der Abweichung von prädictiertem $\hat{y}_i$ zum gemessenen Wert y_i :

$$r_i = \hat{y}_i - y_i.$$

Die Abweichung von der Normalverteilung resultiert aus hohen Streuung der Messungen, dem damit verbundenen Fehler und mutmaßlich an einem noch nicht betrachteten quadratischem Verhalten der Hauptauswirkungen. Da das Modell nur einer ersten Analyse dient, ist dies für den Nachweis signifikanter Parameter ausreichend.

Die Haupteffekte ($\beta_1, \dots, \beta_5$) auf die Merkmale sind in Abbildung 4-12 zu sehen. Das Merkmal $\hat{y}_1$ wird zum Großteil durch die Justagestellen x_3 und x_4 geprägt, wohingegen das Merkmal $\hat{y}_2$ durch die Justagestellen x_3 und x_5 beeinflusst wird. Es zeigt sich ebenfalls,




Bild 4-11: Wahrscheinlichkeitsdiagramme der Residuen

dass das erste Merkmal sensibler bezüglich der Verstellung ist. Die Winkel $\hat{y}_3$ und $\hat{y}_4$ haben jeweils einen ausgeprägten Haupteinfluss (Justagestelle x_5 bzw. x_1), der eine präzise Einstellung des Werkzeugs erschweren kann. Weiterhin sind noch geringere Einflüsse von den Justagestellen x_3 und auch x_4 zu erkennen. Laut den Vorversuchen haben zusätzlich zu den Haupteinflüssen Wechselwirkungen einen signifikanten Einfluss auf die Merkmale.

Fazit

Mithilfe der Voruntersuchungen konnten wesentliche Punkte für das weitere Vorgehen festgehalten werden. Im ersten Schritt wurden Einzelmessungen analysiert und wurde nachgewiesen, dass die Justagestelle x_4 einen deutlichen Einfluss auf das Streuverhalten des Systems ausübt. Aus diesem Grund wird diese für die Hauptversuche auf einen identifizierten Wert festgelegt und nicht mehr variiert. Dies reduziert die notwendigen Versuchsvarianten. Nach der Berechnung eines polynomialen Regressionsmodells erster Ordnung wurde dieses für die weitere Analyse genutzt. Jede Justagestelle übt einen Einfluss auf die gewählten Qualitätsmerkmale aus. Die zweite Justagestelle hat den geringsten Einfluss, kann jedoch noch nicht vollständig ausgeschlossen werden. Daher wird die Justagestelle x_2 weiterhin berücksichtigt. Bei der Analyse wurden vordergründig die Haupteinflüsse analysiert. Es wird festgehalten, dass Wechselwirkungen die Qualitätsmerkmale zusätzlich prägen. Mithilfe der Residuenplots konnte identifiziert werden, dass das für die Voruntersuchungen übliche Regressionsmodell erster Ordnung das Verhalten noch unzureichend abbildet, da




Bild 4-12: Hauptauswirkungen der Stellschrauben auf die Qualitätsmerkmale

insbesondere in den Randbereichen die Wahrscheinlichkeit der Residuen r_i von der Normalverteilung stark abweicht. Es wird angenommen, dass ein Regressionsmodell höherer Ordnung hier Abhilfe schafft.

Nachdem nun die kontrollierbaren Einflussgrößen erfolgreich analysiert wurden, folgt im nächsten Schritt eine Analyse der Störeinflüsse und eine abschließende Zusammenfassung. Darauf aufbauend wird folgend die Architektur für das Einrichtssystem schrittweise systemindividuell ausdetailliert und die Funktionsfähigkeit nachgewiesen.

4.1.2 Voruntersuchung Störgrößenmodell

Ziel dieses Abschnitts ist die Analyse der nicht-kontrollierbaren Einflussgrößen und die Erstellung eines Überblicks der für den Prozess weiter betrachteten Störgrößen. Aufgrund der namensgebenden Eigenschaft können die Auswirkungen der Störeinflüsse, im Gegensatz zu vielen Störeinflüssen selbst, kaum oder nur mit hohem Aufwand gezielt ermittelt werden. Die Störeinflüsse müssen entweder künstlich in den Prozess injiziert werden oder bei Auftritt am Prozess beobachtet werden. Beispielhaft ist eine Blechdicke einfach zu ermitteln, die Auswirkungen unterschiedlich dicker Bänder auf die Qualitätsmerkmale hingegen aufgrund der chargenabhängigen Varianz ist deutlich komplexer. Die Herausforderung hier ist nicht die Messung, sondern die Beschaffung des Materials mit den benötigten Eigenschaften. Im Folgenden werden eine kurze Übersicht über mögliche nicht-kontrollierbare Einflussgrößen gegeben und die wesentlichen Einflüsse identifiziert, um diese später in der Simulationsumgebung implementieren zu können. Bezogen auf den

Folgeverbundprozess werden vier Einflussarten

- Mensch,
- Maschine,
- Material und
- Milieu

der 5M-Methode⁶ näher erläutert.

Auch für den Folgeverbundprozess ist der **Mensch** ein wesentlicher, häufig nicht präzifizierbarer Einfluss. So können bereits bei der Installation des Werkzeugs schwer reproduzierbare Einflüsse entstehen. Exemplarisch können außermittig montierte Werkzeuge durch die hohen Massekräfte einen negativen Effekt auf die Produkt- und Qualitätsmerkmale ausüben. Weiter kann der Bediener durch eine unüblich hohe oder niedrige Schmierstoffmenge einen ungewollten Einfluss auf die Qualitätsmerkmale ausüben. Zusätzlich beeinflusst der Bediener durch diesen Eingriff ebenfalls das Verschleißverhalten des Werkzeugs, welches durch die regelmäßigen Wartungsintervalle beeinflusst wird. Ebenso ist er für die regelmäßige Reinigung des Werkzeugs zuständig: bereits kleine Schmutzpartikel durch Werkzeug- oder Materialabrieb können das Ergebnis signifikant verändern.

Gleichermaßen bedeutsam wie der Mensch ist die **Maschine** für die Qualitätsmerkmale. Durch den Verschleiß des in der Maschine eingebauten Werkzeugs kann sich die Reibung des Systems, somit das Werkzeugverhalten und folglich die Qualitätsmerkmale stetig ändern. Zusätzlich kann durch eine unzureichende oder ungleichmäßige Verteilung der Schmierung die Betriebstemperatur des Werkzeugs ändern und über die Änderung der Materialeigenschaften des Werkzeugs einen Einfluss auf die Produkte ausüben. Weiterhin kann die Materialzuführung, also der Vorschub, einer gewissen Streuung unterliegen und so Stanz- und Biegeergebnisse beeinflussen.

Auch das **Material** prägt die Produktqualität. So können Schwankungen der Materialdicke zu Qualitätsabweichungen und Ausschuss führen. In der Regel werden die vom Hersteller angegebenen Toleranzen in einer Materialcharge nicht ausgeschöpft, allerdings können sich innerhalb des Toleranzbandes signifikante Änderungen über verschiedene Coils ergeben. Ähnlich sind variierende Werkstoffeigenschaften zu bewerten. Auch diese variieren in der Regel für den betrachteten Prozess nicht maßgeblich innerhalb eines Coils, allerdings gibt es über mehrere Chargen bzw. Hersteller hinweg deutliche Unterschiede. Durch die notwendige, zusätzliche Beschichtung des Zielprodukts existiert ein zusätzlicher Einfluss: auch die Beschichtung kann in ihrer Zusammensetzung und Dicke variieren. Zuletzt wird das Material auf Coils angeliefert, durch die Aufwicklung wird das Material unterschiedlich stark vorgekrümmt und Eigenspannungen in das Halbzeug eingebracht, was das Biegeergebnis zusätzlich und anisotrop beeinflusst.

Zusätzlich wirkt die Umwelt des Prozesses, also das **Milieu**, auf die Produktqualität ein. So kann die Umgebungstemperatur in unklimateisierten Produktionshallen zwischen den Jahreszeiten deutlich schwanken und so das Werkzeug, aber auch die Betriebsstoffe beeinflussen. Neben der Temperatur können sich auch Vibrationen durch weitere Anlagen

⁶Die hier fehlende Einflussart, die Messung, ist für das Einrichtassistenzsystem nicht im Optimierungsfokus und wird daher hier nicht betrachtet, ist aber für die Optimierung eines Prozesses von grundlegender Bedeutung.

negativ auf die Produktqualität auswirken. Diese können zum einen zu einem Qualitätsdrift, aber auch zu einer erhöhten Prozessstreuung führen.

Dieser kurze Überblick zeigt bereits verschiedene Einflüsse auf, die die Produkt- und Qualitätsmerkmale des Zielprozesses beeinflussen. Sie differieren ebenfalls bezüglich ihrer Messbarkeit. So ist vorstellbar, dass viele Werkstoffeigenschaften zwar prinzipiell messbar sind, jedoch häufig zerstörungsfreie inline-Messsysteme fehlen oder nicht wirtschaftlich sind. Ähnliches gilt für den Schmierzustand oder auch die Vibrationen externer Anlagen. Sie gelten damit als nicht-kontrollierbar und nicht-messbar (siehe Begriffsdefinitionen in Kapitel 3). Diese Größen müssen weiterhin durch die Kompensationsstrategie eliminiert werden, was im Abschnitt 3.3.4 vorgestellt wird.

Andere Störgrößen hingegen gelten als nicht-kontrollierbar, aber messbar und können mit den Qualitätsmerkmalen korreliert werden, um die Präzision des Gesamtmodells stetig zu steigern. Hierzu zählen zum Beispiel

- die Umgebungstemperatur,
- der Zeitpunkt seit der letzten Wartung als Repräsentation des Verschleißes oder
- die Materialdicke.

Aufgrund der sehr guten, wirtschaftlichen Messbarkeit und damit Realisierbarkeit werden diese Einflussgrößen im späteren Verlauf in einer simulationsgestützten Validierung für die Betrachtung nicht-kontrollierbaren Einflussgrößen implementiert und die Funktionsfähigkeit der Systematik nachgewiesen.

4.1.3 Zusammenfassung der Analyse

Das Ziel der Analyse war die Identifikation der wesentlichen Ein- und Ausgänge des Systems FVWZ. Hierbei werden kontrollierbare und nicht-kontrollierbare Einflussgrößen als Eingänge unterschieden und Produkt- und Qualitätsmerkmale als Ausgänge. In Abbildung 4-13 werden die wesentlichen Eigenschaften des Folgeverbundwerkzeugs aggregiert dargestellt.




Bild 4-13: Zusammenfassung über Ein- und Ausgänge des FVP

Der Ausgang des Systems sind Produktmerkmale, wovon in diesem Abschnitt vier wesentliche **Qualitätsmerkmale** für die weitere Betrachtung identifiziert wurden. In dem betrachteten Anwendungsbeispiel ist eine automatisierte Erfassung dieser Qualitätsmerkmale möglich, was eine schnelle Auswertung der Produktqualität ermöglicht.

Die **Stellschrauben** stellen die hauptsächlichen kontrollierbaren Einflussgrößen dar. Die Analyse, basierend auf einem teilfaktoriellen Versuchsplan, hat die Signifikanz der Justagestellen auf die Produktqualität bestätigt. Es ist festzuhalten, dass die Positionen der Stellschrauben in dem Beispielsystem nicht direkt messbar sind, sondern über eine externe Einheit erfasst werden müssen. Hierbei wurde auf eine manuelle Erfassung mittels mechanischem Anschlag als Referenzposition zurückgegriffen. Es hat sich in der Analysephase gezeigt, dass die Justagestelle 4 einen wesentlichen Einfluss auf die Streuung der Qualitätsmerkmale hat. Aus diesem Grund wird die Justagestelle im Folgenden nicht mehr variiert und auf den identifizierten Wert fixiert. Hierbei hat sich der Wert der Analysephase für die Anwendung der Einrichtsystematik gezeigt: der finale Versuchsplan kann aufgrund des Ausschlusses der Justagestelle im Umfang reduziert werden.

Zusätzlich wurde eine Übersicht über nicht-kontrollierbare Einflüsse, den **Störgrößen**, gegeben. Diese ändern über schwer abzuschätzende Zeiträume ihren Einfluss auf die Produktqualität: folglich ist der Einfluss kaum über definierte Versuche realitätsnah ermittelbar. Zusätzlich sind einige von den hier betrachteten Störgrößen kaum oder nur schwer messbar. Daher wurde eine Auswahl relevanter und wirtschaftlich messbarer Störgrößen identifiziert, die später für die Integration in das Gesamtmodell berücksichtigt werden. Die nicht-messbaren Störungen werden weiterhin von der Kompensationsstrategie eliminiert. Die **Maschinenparameter** werden in der Regel von den Entwicklern einmal festgelegt und anschließend nicht mehr variiert. Ein Einfluss auf die Produktqualität ist dennoch vorhanden. Da es sich hier um Software-Parameter handelt ist eine zufällige Variation dieser Einflüsse jedoch ausgeschlossen.

In diesem Abschnitt wurden die Grundlagen für die im nächsten Abschnitt folgende Anwendung der Systematik, genauer die Ausdetaillierung der Einrichtarchitektur gelegt. Es wurden die kontrollierbaren und nicht-kontrollierbaren Einflussgrößen charakterisiert und festgelegt, welche im nächsten Abschnitt berücksichtigt werden.

4.2 Anwendung der Einrichtsystematik

Folgend wird die erarbeitete Architektur der Systematik für das Einrichten auf den bereits analysierten Folgeverbundprozess angewendet. Zunächst wird in Abschnitt 4.2.1 das Maschinenmodell für die kontrollierbaren Einflussgrößen auf Basis der statistischen Versuchsplanung entwickelt. Im Anschluss daran werden die Modelle validiert und für ein erstes Einrichten und eine Störkompensation genutzt. Dies entspricht dem Ersteinsatz in der Produktion ohne zusätzliches Wissen über die nicht-kontrollierbaren Einflüsse. Anschließend wird ein simulationsgestützter Funktionsnachweis für die Integration der nicht-kontrollierbaren Störungen erbracht, um die entwickelte Systematik zu komplettieren.

4.2.1 Stellgrößenmodell

In diesem Abschnitt wird das Maschinenmodell für den FVP ermittelt. Für den Prozess existieren FE-Simulationen, die einzelne Prozessschritte, sprich Biegeschritte, abbilden. Ein Modell vom Gesamtsystemverhalten der Stellschrauben auf die signifikanten Qualitätsmerkmale existiert nicht, daher wäre der Aufwand für eine Neuentwicklung eines bedarfsgerechten FE-Modells zu groß. Resultierend wird das Maschinenmodell auf Basis der statistischen Versuchsplanung als Regressionsmodell ausgeführt. Im Folgenden werden die notwendigen Schritte von der Versuchsplanung bis zum Maschinenmodell näher erörtert.

Auswahl des Versuchsplans

Der Versuchsplan dient, wie bereits bei den Vorversuchen, der zielgerichteten Untersuchung des FVP und bildet die Basis zur Berechnung der Stellgrößenmodelle. So wird zum einen festgelegt, welche Faktorkombinationen getestet und zum anderen in welcher Reihenfolge die Versuche durchgeführt werden (siehe Abschnitt 2.4). In den Vorversuchen wurden vier kontrollierbare Einflussgrößen identifiziert, die die vier wesentlichen Qualitätsmerkmale wesentlich beeinflussen. Nichtlineare Auswirkungen auf die Qualitätsmerkmale konnten noch nicht ausgeschlossen werden, wurden bei der Residuenanalyse sogar indiziert: ein dementsprechendes Modell höherer Ordnung muss vorgesehen werden. Für den Folgeverbundprozess ist zusätzlich eine strikte Einhaltung des Parameterraums erforderlich. Das heißt, dass die einzelnen Prozessparameter nur innerhalb der spezifizierten Grenzen verstellt werden dürfen, um eine Schädigung des Werkzeugs zu vermeiden. Unter Berücksichtigung dieser Rahmenbedingungen wird nun ein Versuchsplan ausgewählt und angewendet.




Bild 4-14: Central Composite Design - Inscribed: dargestellt im zweidimensionalen Parameterraum

Ein zentral zusammengesetzter Versuchsplan (central composite design – CCD, siehe Abbildung 4-14) erfüllt die oben genannten Voraussetzungen. Bei dieser Methode wird ein voll- oder teilfaktorieller zweistufiger Versuchsplan (grün) um weitere Versuche ergänzt, die eine dritte Stufe beinhalten. Diese Versuche beinhalten sowohl ein mehrmaliges Anfahren des Mittelpunktes (blau im Bild), als auch weitere sternförmig verteilte Versuche (orange). Das „inscribed Design“ belässt im Gegensatz zu den üblichen CCD die Sternpunkte auf den Stirnflächen des Faktorraums und rückt die Eckpunkte des Faktorraums

ein. Es ergibt sich so eine approximiert sphärische Abdeckung des Faktorraums. Dies hat den Vorteil, dass wie beim konventionellen CCD eine Trennung der quadratischen Einflüsse ermöglicht wird. Dem gegenüber steht ein kleinerer Gültigkeitsbereich des Modells bezüglich des Parameterraums, da eine Extrapolation der Ergebnisse über die Parametergrenzen hinaus nicht legitim ist.

Der gesamte Versuchsplan ist im Anhang 5.2 in der Tabelle A0-3 abgebildet. Das Central Composite Design Inscribed (CCDI) besteht aus einem vollfaktoriellen Versuchsplan für die vier Einflussgrößen, den Stern-, sowie den Zentralpunkten in fünffacher Ausführung. Weiterhin wurden, wie bei der Analyse auch, noch weitere Versuche durchgeführt, die für die Validierung der Modelle genutzt werden. In dem Versuchsplan werden die Einflussgrößen auf einen Bereich von ± 1 normiert, um eine übersichtliche Darstellung zu erhalten. Für die Versuchsdurchführung wird der Versuchsplan „randomisiert“ (siehe Anhang, Tabelle A0-4), das heißt, die Versuche werden zufällig und nicht in der sortierten Reihenfolge durchgeführt, um systematische Fehler bei den Einstellungen zu vermeiden. Für jede vom Versuchsplan vorgesehene Konfiguration wird, wie im letzten Abschnitt abgeschätzt, eine definierte Produktanzahl gefertigt, um die Messstreuung zu kompensieren und den Erwartungswert der Qualitätsmerkmale so mit hinreichender Genauigkeit ermitteln zu können.

Auswertung und Modellregression

In Abbildung 4-15 sind die fünf Zentralpunktversuche zu erkennen, die der Bewertung der Versuchsreproduzierbarkeit dienen. Es zeigt sich, dass die Streuung der Merkmale gegenüber den Vorversuchen deutlich verringert werden konnte. Dies liegt zum einen an der Fixierung der Justagestelle x_4 und zum anderen an einem zusätzlich angepassten Stellbereich der einzelnen Justagestellen.

In der Abbildung zeigt sich eine gute Reproduzierbarkeit der Messungen, auch unter Rücksichtnahme der prozessbedingten Streuung. Aufgrund dieser Streuung wird der Median, als ausreißerunempfindliches statistisches Merkmal, für die Berechnung der Regressionsmodelle genutzt. Es ist auffällig, dass der letzte Versuch (in Abbildung 4-15 V_{05}) eine deutliche Abweichung von den vorherigen Versuchen zeigt. Die Ursache hierfür war der manuell notwendige Eingriff und das fehlende Feedback des Systems bezüglich der aktuellen Einstellung. Konkret bedeutet dies, dass das Werkzeug bei diesem Versuch anders eingestellt worden sein muss, als es der Versuchsplan vorgegeben hat. Dieser Versuch wird daher als Ausreißer klassifiziert. Es lässt sich festhalten, dass die Versuche bezüglich der Qualität eine deutliche Verbesserung zu den Vorversuchen sind und somit zur Berechnung der Regressionsmodelle genutzt werden können.

Für die Modellerstellung werden die Versuche des CCI-Versuchsplans für eine Regression genutzt. Für das Modell wird, wie auch in der Literatur üblich, ein quadratischer Ansatz gewählt:

$$\hat{y}_i = \beta_0 + \sum_{i=1}^5 \beta_i x_i + \sum_{i=1}^5 \beta_{i,i} x_{i,i}^2 + \sum_{i=1}^4 \sum_{j=1}^5 \beta_{i,j} x_i x_j.$$

Im Gegensatz zu den Vorversuchen sind in diesem Modell ebenfalls die quadratischen Terme $\beta_{i,i} x_{i,i}^2$ enthalten. Diese werden aufgrund des ausführlicheren Versuchsplans er-




Bild 4-15: Auswertung der Zentralpunktversuche

möglichst. Für diese Funktion werden eine Regressionsanalyse durchgeführt und anschließend über den F-Test (siehe Abschnitt 2.4) die nicht signifikanten Einflüsse aussortiert. Um die Modellqualität zu bewerten und ggf. Ausreißer zu identifizieren werden die Auftretenswahrscheinlichkeiten der Residuen bezüglich einer Normalverteilung untersucht. Diese ist in Abbildung 4-16 zu sehen.

An diesen Grafiken können die Versuchsausreißer identifiziert werden, wie in der Grafik für das Modell $\hat{y}_3$ sehr deutlich zu erkennen ist. Im Wesentlichen liegen die Residuen auf der Geraden, die einer Normalverteilung entspricht. Ein Punkt hingegen liegt sehr weit außerhalb dieser Geraden (ungefähr bei 4mm/0.99). Dies ist der gleiche Versuch, der bereits im Vorfeld in der Untersuchung der Zentralpunkte (siehe Abbildung 4-15) als Ausreißer identifiziert wurde. Zusätzlich ist ein weiterer Versuch in dem Modell y_2 auffällig, sodass diese beiden Versuche von der folgenden Regressionsanalyse ausgeschlossen werden. Aus dem Ergebnis ergibt sich die neue Auftretenswahrscheinlichkeit der Residuen aus Abbildung 4-17. Bei dieser Grafik ist in den unteren beiden Plots die Skalierung im Vergleich zur Abbildung 4-16 reduziert.

Es zeigt sich, dass insbesondere bei den Modellen für die Merkmale $\hat{y}_2$ und $\hat{y}_3$ die Verteilung der Residuen deutlich näher an der Normalverteilung liegt. Die Modelle werden daher als qualitativ hochwertiger eingestuft. Es ergibt sich nun die Frage, welche Justagestellen eine signifikante Auswirkung auf die jeweiligen Qualitätsmerkmale haben.

In Abbildung 4-18 sind die aus der ANOVA identifizierten Einflussgrößen auf die zugehörigen Merkmale abgebildet. Bei einer Berücksichtigung eines Einflusses im Modell wird dies in der Abbildung mit einem Kreis (○) gekennzeichnet. Die Kennzeichnung mit einem grünen Hintergrund zeigt die Prognose aus der Analysephase (siehe Abschnitt 4.1) an. Der obere Teil der Tabelle stellt die Hauptauswirkungen dar, die ebenfalls in der Ana-




Bild 4-16: Auftretenswahrscheinlichkeit der Modellresiduen

lysephase abgeschätzt wurden, der untere Teil beinhaltet die quadratischen Einflüsse und die Wechselwirkungen. Es zeigen sich Übereinstimmungen der Prognose mit den aus der Regressionsanalyse ermittelten signifikanten Einflussgrößen, allerdings wurden viele Auswirkungen deutlich unterschätzt. Bei dem Merkmal $\hat{y}_1$ wurden einige Haupteinflüsse überschätzt und der Einfluss der fünften Justagestelle nicht ermittelt. Zusätzlich zu den Haupteffekten treten ebenfalls Wechselwirkungen von den Justagestellen und eine quadratische Abhängigkeit von Justagestelle fünf auf. Es zeigt sich auch hier, dass Prognosen von Experten wichtig sind, aber keine systematische Analyse ersetzen. Exemplarisch ergibt sich daher für dieses Modell die Gleichung:

$$\hat{y}_1 = \beta_0 + \beta_1 x_1 + \beta_3 x_3 + \beta_5 x_5 + \beta_{1,3} x_1 x_3 + \beta_{5,5} x_5^2.$$

In der Abbildung 4-18 ist zusätzlich zu sehen, dass die Qualitätsmerkmale $\hat{y}_2$ und $\hat{y}_3$ von den gleichen Einflussgrößen abhängen. Dies wurde in der Analysephase bereits korrekt prädictiert, allerdings wurde auch hier die Vielfalt der Einflüsse unterschätzt, sodass ebenfalls die Justagestelle x_1 und die Wechselwirkungen von Justagestelle x_1 und x_5 , sowie der quadratische Einfluss der letzteren, signifikante Auswirkungen auf die beiden Merkmale zeigen. Das letzte Merkmal $\hat{y}_3$ wird maßgeblich von der Justagestelle x_1 beeinflusst, wie bereits im Vorfeld korrekt erkannt, allerdings wirken sich die Justagen x_1 und x_5 ebenfalls auf dieses Qualitätsmerkmal aus.

Das Ergebnis der Regressionsanalyse sind vier Modelle, die einen funktionalen Zusammenhang zwischen den Justagestellen $\mathbf{x}$ und den jeweiligen Qualitätsmerkmalen $\hat{\mathbf{y}}$ abbilden. Es wurden in den Modellen nur statistisch signifikante Einflüsse berücksichtigt,




Bild 4-17: Auftretenswahrscheinlichkeit der Modellresiduen mit ausgeschlossenen Versuchen

indem eine ANOVA angewendet wurde. Die Qualität der Modelle wurde mithilfe von Wahrscheinlichkeitsplots der Modellresiduen sichergestellt. Es folgt nun die Validierung der Modelle mithilfe der zusätzlichen Messungen.

Validierung der Stellgrößenmodelle

Für die Validierung wurden während der Versuche des CCD-Designs zusätzliche Experimente durchgeführt. Hierfür wurde die einzelne Justagestelle je einmal auf ± 0.5 gestellt, während die anderen Justagestellen auf den Wert des Zentralpunkts gesetzt wurden. Somit stehen acht zusätzliche Messungen zur Validierung zur Verfügung.

In Abbildung 4-19 ist das Ergebnis der Validierung dargestellt. In den Diagrammen sind die prädizierten Qualitätsmerkmale über das durch Messungen nachgewiesene Verhalten aufgetragen. Idealerweise würden die Messpunkte (in grün) exakt auf der grauen Diagonalen liegen: die Prädiktion würde genau der Messung entsprechen. Bei den Merkmalen y_1 und y_2 ist zunächst eine geringe Streuung der Validierungsmessungen über den betrachteten Bereich zu beobachten. Dies liegt an einer „zu geringen“ Einstellmöglichkeit für diese robusteren Merkmale. Die Qualitätsmerkmale können nur in geringem Maße mit den Justagestellen beeinflusst werden und ist konsistent zu den Erkenntnissen aus der Analysephase im Abschnitt 4.1. Nichtsdestotrotz ist die Validierung dieser Modelle erfolgreich: die Messpunkte streuen in einem kleinen Bereich um die Diagonale.

	Justage	$\hat{y}_1$	$\hat{y}_2$	$\hat{y}_3$	$\hat{y}_4$
Haupteffekte	x_1	○	○	○	○
	x_2				
	x_3	○			○
	x_4				
	x_5	○	○	○	○
Neben- effekte	x_1x_3	○			
	x_1x_5		○	○	
	x_5x_5	○	○	○	

Bild 4-18: Prognostizierte (grün) und ermittelte (○) Auswirkung der Stellschrauben auf die Merkmale. Bei den fehlenden Nebeneffekten konnte keine Signifikanz nachgewiesen werden.

Ähnliches gilt für die Prädiktion des Merkmals y_3 , welches mit einer größeren Varianz und einer sehr guten Präzision auffällt. Etwas ungenauer wird das Merkmal y_4 vorausgesagt. Bei diesem Modell fällt eine größere Streuung um die Diagonale auf, das Modell unterschätzt in einigen Fällen den realen Wert. Dieses Verhalten war bereits aufgrund der höheren Streuung in den Messungen (siehe Abbildung 4-15) zu erwarten. Auch dieses Modell liefert zuverlässige Ergebnisse, sodass die Modelle im nächsten Schritt für die Validierung der Systematik angewendet werden können.

4.2.2 Validierung der Einrichtsystematik mit dem Stellgrößenmodell

Nachdem nun das Stellgrößenmodell entwickelt und validiert wurde, wird das Modell im Folgenden in der Einrichtstrategie genutzt. Das Einrichten, gestützt auf das Maschinenmodell, steht laut des Konzepts dem Bediener von Produktionsbeginn an zur Verfügung. Hierfür werden zunächst mit dem Stellgrößenmodell die initialen Startwerte berechnet und anschließend Produkte gefertigt und vermessen. Die Störungen wirken sich auf die Qualitätsmerkmale aus, die erfasst und dem System zurückgeführt werden. Dieses berechnet dann basierend auf dem Stellgrößenmodell eine optimierte Kompensation (siehe Kapitel 3).

Das Maschinenmodell wurde hierfür in eine Optimierung der NLOpt-Toolbox [Joh19] eingebettet. Für die Optimierung wird der Algorithmus COBYLA [Pow94] genutzt: ein lokaler, gradientenfreier, nichtlinearer Optimierer. Dieser berechnet die (aufgrund der externen Einflüsse) momentanen Optima für die Stellschrauben. In diesem Fall ist ein lokaler Optimierer ausreichend, da in der Regel durch den Prozess ein eindeutiges Optimum vorgegeben ist, welches sich in der Nähe der Starteinstellungen befindet. Die Effizienz und damit Rechenzeit der Optimierung spielt in der vorliegenden Anwendung zum Einrichten nur eine untergeordnete Rolle.

Das Einrichten gestaltet sich wie folgt. Zunächst wird vom Bediener das Modell des vor-




Bild 4-19: Vergleich der Modelle mit zusätzlichen Messungen

liegenden Werkzeugs ausgewählt. Das Modell wird geladen und für eine Optimierung genutzt, mit der optimierte Startwerte berechnet werden. Hierfür wird die Zielfunktion aus Gleichung (3-3) verwendet und unter den Nebenbedingungen (siehe Abschnitt 3.3.3) für die Justagestellen minimiert. Die Startwerte für den Optimierungsparameter sind je nach Kenntnisstand entweder die aktuellen Startwerte an dem Werkzeug oder der Zentralpunkt des CCD-Versuchsplans. Das Ergebnis wird dem Maschinenbediener ausgegeben, der die Einstellung am Werkzeug vornimmt.

In Abbildung 4-20 werden die mithilfe der Optimierung berechneten Produktionseinstellungen mit historischen Einstellungen verglichen. Die erfahrungsbasierten Einstellungen wurden bei dem letzten Werkzeugeinsatz für die Produktion funktionsfähiger Produkte verwendet. Es wird deutlich, dass sich die Einstellungen nur in sehr kleinem Maße voneinander unterscheiden. Das bedeutet, dass das Modell in Kombination mit der Optimierung zu einem ähnlichen Ergebnis gekommen ist wie der Maschinenbediener mit seinem Erfahrungswissen. Dies zeigt ebenfalls die Eignung der vorgeschlagenen Zielfunktion, die die intuitive Gewichtung und Priorisierung der Merkmale seitens der Maschinenbediener sehr gut trifft. Allerdings kann davon ausgegangen werden, dass auch wenn der Maschinenbediener für den früheren Betriebspunkt Einstellungen gefunden hat, diese für die momentanen nicht-kontrollierbaren Einflussgrößen nicht mehr optimal sind. Es zeigt sich aber auch, dass das gewählte Vorgehen zur Berechnung der Startwerte und damit ein Teil der Vorgehensweise für die Entwicklung des EAS validiert werden konnte. Der Vorteil ist, dass nun auch unerfahrenere Bediener eine gute Starteinstellung für den Prozess finden können.




Bild 4-20: Vergleich erfahrungsbasierter Produktionseinstellungen mit den Modellberechnungen

Die resultierenden Qualitätsmerkmale basierend auf den berechneten Startwerten sind in Abbildung 4-21 zu sehen. Die linken Diagramme zeigen die Produktmerkmale während des Einstellvorgangs selbst, der ab dem Bauteil 125 bis zum Bauteil 140 andauert. Der Maschinenbediener fertigt mit dem Prozess im Anschluss die definierte Anzahl an Produkten (hier 150), um das Einstellergebnis zu kontrollieren. Der Abstand zwischen den Korrekturen an den beiden Merkmalen in den linken Diagrammen ist mit der örtlichen Verteilung der Justagestellen zu erklären. Es zeigt sich zunächst, dass die historischen Produktionseinstellungen (linke Diagramme, bis Bauteil 125) für die aktuellen nicht-kontrollierbaren Einflussgrößen insbesondere für die Merkmale y_3 und y_4 nicht im Bereich um den Nennwert liegen. Während das Qualitätsmerkmal y_3 noch im Toleranzbereich liegt, ist das Merkmal y_4 auf der Grenze des Toleranzbereichs. Die Merkmale y_1 und y_2 hingegen sind deutlich robuster gegenüber Einflüssen von außen und liegen beide nah am Nennwert innerhalb des Toleranzbandes.

Nach der Einstellung der von der Optimierung berechneten Startwerte (ab Bauteil 140 in den linken Diagrammen und die rechten Diagramme) verbessern sich die Qualitätsmerkmale deutlich. Es zeigt sich, dass das Merkmal y_3 präziser eingestellt werden konnte als das Merkmal y_4 . Dies ist auf die streuungsbehaftete Messung des Merkmals y_4 zurückzuführen und die daraus resultierende geringere Vorhersagegenauigkeit, die auch in der Abbildung beobachtet werden kann.

Da im Stellgrößenmodell nicht berücksichtigte Einflüsse das Ergebnis noch stark vom Optimum, den Nennwerten, abweichen lassen, können die Auswirkungen der anliegenden Störungen kompensiert werden. Hierfür wird die in Abschnitt 3.3.4 beschriebene Kompensationsstrategie genutzt. Die Messung wird hierfür aus dem angeschlossenen Messsystem ausgelesen und verarbeitet. Das Ergebnis, die absoluten Messwerte der Qualitätsmerkmale, wird dem Optimierer zugeführt und ebenfalls in einer Optimierung mit der Zielfunktion nach Gleichung (3-5) verwendet. Als initiale Optimierungsparameter wird hierbei auf die letzte Einstellung gesetzt. Dem Bediener können entweder die absoluten Einstellungen oder die zur momentanen Konfiguration relativen Einstellungen ausgege-




Bild 4-21: Justage der berechneten Startwerte (links) und resultierende, stationäre Qualitätsmerkmale (rechts)

ben werden. Letzteres ist im Fall des FVWZ komfortabler.

Die Auswirkungen dieser Kompensation ist in Abbildung 4-22 abgebildet. In den linken Diagrammen ist wie in der Abbildung zuvor die Verstellung der Justagestellen abgebildet und in den rechten Diagrammen der stationäre Zustand des Systems. Wie in den linken Diagrammen zu erkennen, werden die Längen der Merkmale y_1 und y_2 kaum beeinflusst, da diese bereits in einem sehr guten Bereich sind. Während der Winkel y_3 eine kleine Änderung erfährt, wird durch die Kompensationsjustage das Qualitätsmerkmal y_4 deutlich korrigiert. Das Resultat sind sehr gut eingestellte Merkmale, die für die Produktion genutzt werden können. Für einen Bediener erfordert eine solche Kompensation eine gute Einarbeitung in das Werkzeugverhalten, da er die quantitativen Auswirkungen jeder Stellschraube abschätzen muss, um eine Korrektur zu ermitteln. Somit konnte in diesem Abschnitt neben der in dieser Arbeit erarbeiteten Strategie zur Ermittlung der Startwerte ebenfalls die Kompensationsstrategie validiert werden.

Fazit

In diesem Abschnitt wurde das zuvor entwickelte Stellgrößenmodell in Kombinati-




Bild 4-22: Justage der Kompensationseinstellungen

on mit der Systematik an einem FVP erprobt. Ein Vergleich mit manuell ermittelten Einstellungen des Werkzeugs hat gezeigt, dass mithilfe des EAS der Prozess wie durch einen erfahrenen Maschinenbediener eingerichtet werden konnte. Bereits die Berücksichtigung der kontrollierbaren Einflussgrößen, in Zusammenwirken mit der vorgestellten Optimierung und der Kompensationsstrategie, konnte das Einrichten des Werkzeugs deutlich vereinfachen. Vereinfachen heißt hier, dass durch die systematische Vorgehensweise der Maschinenbediener zielgerichtet zu den optimalen Einstellungen geführt wird. Die Einarbeitung in komplexe Werkzeugdokumentationen entfällt, Fehler durch falsche Justagen werden reduziert. Mit der Validierung der Systematik hat sich gezeigt, dass das Zusammenspiel von Stellgrößenmodell, Startwertberechnung und Kompensationsstrategie sehr gut funktioniert. Die gewählte Zielfunktion bildet das intuitive Verhalten eines erfahrenen Maschinenbedieners sehr gut ab. Auch kleine Modellungenauigkeiten wie die des Qualitätsmerkmals y_4 konnten mithilfe der vorgeschlagenen Module sehr gut kompensiert werden.

Es hat sich gezeigt, dass allein die Berücksichtigung des Stellgrößenmodells noch Potenzial zur Optimierung offen lässt, um direkt ein sehr gutes Einrichtungsergebnis nach der Berechnung der Startwerte zu berechnen. Dies ist insbesondere bei kostenintensi-

ven Produkten weiterhin ein Optimierungspotenzial. Aus diesem Grund wird im weiteren Verlauf die Integration der modellierten Auswirkungen nicht-kontrollierbarer, aber messbarer Einflussgrößen verfolgt und vorgestellt.

4.2.3 Störgrößenmodell

Im Folgenden wird nachgewiesen, ob durch die Integration der Störgrößenmodelle die Berechnung der Startwerte präziser wird. Grundlage hierfür ist die Erfassung aller relevanten messbaren Störgrößen für das System: Um auch ein solch momentan noch hypothetisches Zukunftsszenario einer durchgängig digitalisierten Produktion und deren Vorteile mit dem EAS abzudecken, wird dieses Szenario modellbasiert untersucht. Das Ziel der Simulation ist die synthetische Datengenerierung, um Störgrößenmodelle basierend auf diesen Daten zu berechnen und in die Architektur der Systematik integrieren zu können. So kann im nächsten Abschnitt 4.2.4 die Funktionsweise und Plausibilität der Einrichtstrategie nachgewiesen werden.

Der simulationsgestützte Test bietet dabei mehrere Vorteile. Zum einen existiert an dem betrachteten Prozess keine Sensorik, die die identifizierten Störgrößen aufnehmen könnte. Das heißt für eine Validierung am Prozess müsste kostenintensive Sensorik integriert werden. Zusätzlich wurde für die Produktion noch keine Infrastruktur zur Erfassung und Verarbeitung solcher Datenmengen aufgebaut. Es müssten provisorische Lösungen implementiert oder ebenfalls zusätzliche höhere Investitionen getätigt werden. Ein weiteres Hindernis wäre die Bestimmung der aktuellen Justagepositionen. Diese weisen momentan keine Sensorik auf, sodass die notwendige Ermittlung der Eingangsdaten während der Produktionszeit sehr fehlerbehaftet wäre. Für die durchgeführten Versuche wurden diese manuell erfasst. Ein Lösungsansatz wäre, dass die Maschinenbediener die aktuelle Konfiguration über einen längeren Zeitraum dokumentieren. Dies wäre eine deutliche Mehrbelastung für die Maschinenbediener und würde zu Akzeptanzproblemen führen, sodass dieser Ansatz wenig nachhaltig wäre. Der letzte Punkt ist die deutlich kürzere Zeitspanne, die eine solch simulationsgestützte Validierung benötigt. Aus diesen Gründen wird in diesem Kapitel der simulationsgestützte Funktionsnachweis geführt und folgendes Vorgehen gewählt:

1. Integration der identifizierten Störungen in das Maschinenmodell.
2. Durchführung einer Monte-Carlo-Simulation für einen definierten Produktionszeitraum.
3. Entwicklung eines datengetriebenen Modells und Integration in die Systematik.

Nachdem die Einrichtarchitektur und somit die Einrichtsystematik komplettiert wurde, kann im nächsten Abschnitt die Verifikation erfolgen.

Synthetische Produktionsdaten

Wie in Abschnitt 4.1 analysiert, werden im Folgenden die Störgrößeneinflüsse, also

- die Temperatur T ,
- die Blechdicke d und

- der Verschleiß V

modelliert. Diese ergeben, wie in Abbildung 4-23 zu erkennen, zusammen mit dem Maschinenmodell ein Referenzmodell für das FVWZ. Das Referenzmodell besteht dabei aus




Bild 4-23: Referenzmodell des FVWZ

dem bereits bekannten Stellgrößenmodell, welches mithilfe der statistischen Versuchsplanung (siehe Abschnitt 4.2.1) erstellt wurde. Neben den Stellgrößen wirken sich nun ebenfalls die Störgrößen (T , d und V) auf die Qualitätsmerkmale aus. In dem Referenzmodell wird zunächst abgebildet, wie sich diese Störungen auf den Biegespalt s auswirken, sodass sich anhand dieses Spalts über die Aktorkinematik eine äquivalente Stellgrößenänderung Δx berechnen lässt. Für das Referenzmodell wird angenommen, dass sich die Störgrößen in dem Prozess wie eine Veränderung der Stempelposition auswirken, dies ist in Abbildung 4-24 mit dem Biegespaltmodell illustriert und wird folgend plausibilisiert.




Bild 4-24: Biegespaltmodell: Auswirkungen der Störungen auf eine beispielhafte Biegeoperation

Über die Stellschrauben wird während des Einrichtens der Biegekern, in einigen Konfigurationen auch Treiber genannt, über ein Keilschiebersystem in der Höhe verstellt. Dem

Biegestempel wird dabei während des Betriebs über die Schnellläuferpresse eine feste Bewegung mit festem Hub s_{BS} aufgeprägt. Eine mögliche Auswirkung einer Störung ist nun, dass sich der Biegespalt s_B zwischen den beiden Stempeln verändert. So kann beispielhaft die Temperatur beide Stempel und das Schiebersystem kontrahieren oder expandieren, ein Halbzeug kann (innerhalb der Toleranz) dicker/dünnere sein oder aufgrund von Verschleiß wird Material von den Stempeln abgetragen. Dadurch vergrößert oder verkleinert sich der Biegespalt s_B und beeinflusst so die Qualitätsmerkmale. Eine Vergrößerung dieses Biegespalts kann ebenfalls als Verringerung der Biegekernhöhe interpretiert und damit als Reduktion der Stellgrößen aufgefasst werden. Basierend auf dieser Verschiebung werden in dem Modell die Qualitätsmerkmale mithilfe des Stellgrößenmodells variiert. In dem Referenzmodell werden dabei die Auswirkungen der kontrollierbaren und nicht-kontrollierbaren Störungen im Folgenden separat berücksichtigt und somit impliziert, dass zunächst keine Wechselwirkungen stattfinden. Für die abschließende Integration der Störgrößen in das Referenzmodell fehlt zunächst ein funktionaler Zusammenhang zwischen aufgetretener Störgröße (Temperatur, Verschleiß, Blechdicke) und der resultierenden Auswirkung auf den Biegespalt. Diese werden im Folgenden näher erörtert.




Bild 4-25: Systembetrachtung der Biegespaltmodelle für die Temperatur, Blechdicke und Verschleiß

Für die Temperatur wird angenommen, dass die Betriebstemperatur aufgrund einer veränderten Umgebungstemperatur oder auch einer höheren inneren Wärmeentwicklung variiert. Die Betriebstemperatur hat einen Effekt auf das Werkzeug und die filigranen Schieber und Biegestempel, sodass sich diese (verglichen mit einer Referenztemperatur) expandieren oder kontrahieren. Das Modell für die Temperatúrausdehnung Δs_T des Materials sei linear [DD11, Seite 188]

$$\Delta s_T(T) = s_{T,0} \alpha_T (T - T_0)$$

und abhängig von der Ausgangslänge $s_{T,0}$ bei der Referenztemperatur T_0 , dem Wärmeausdehnungskoeffizienten α_T sowie der aktuellen Materialtemperatur T . Für das Störgrößenmodell (siehe Abbildung 4-25) wird somit eine virtuelle Verschiebung der Stellschrauben (Δx_T) berechnet, indem die Übersetzungsverhältnisse in dem Keilschiebersystem in einer resultierenden Gesamtlänge $s_{T,0}$ berücksichtigt und mit der Gewindeteilung der Stellschrauben ϕ multipliziert werden. Aufgrund der Übersetzungen sind Temperatúrausdehnungen direkt am Biegestempel signifikanter als die Ausdehnungen an der Stellschraube.




Bild 4-26: Qualitativer Verlauf der Biegespaltänderung Δs_V über die Anzahl der Hube V

Der Einfluss der Blechdicke wird ähnlich modelliert. Es wird angenommen, dass die Abweichung der Blechdicke d sich direkt auf den Biegespalt s_B auswirkt. Es gilt daher

$$\Delta s_M = \Delta d = d - d_n.$$

Auch diese Änderung des Biegespalts kann in eine äquivalente Stellgrößenverschiebung x_d unter Berücksichtigung der Übersetzungsverhältnisse in dem Schiebersystem umgerechnet werden.

Die letzte Störgröße, der Verschleiß, wird über die vergangenen Hube V des FWZ modelliert. Es wird angenommen, dass durch die Nutzung des Werkzeugs das Material an den biege relevanten Stempeln abgenutzt wird. Die Abnutzung des Materials wird über eine logarithmische Gleichung

$$\Delta s_V = \log_{a_V} (b_V V + 1)$$

modelliert. Die Variablen a_V und b_V werden zur Parametrisierung der Funktion genutzt. Hierbei wird über den funktionalen Zusammenhang angenommen, dass der abrasive Verschleiß nach einer kurzen Zeit stärker ansteigt und sich einem Grenzwert annähert, wie in Abbildung 4-26 zu sehen. Eine weitere Annahme für das Modell stellt die Festlegung des Grenzwerts des resultierenden Gesamtmaterialabtrags Δs_V auf $10\mu\text{m}$ dar. Dieser wird so definiert, dass er sich nach der Hubzahl einstellt, die innerhalb einer üblichen Werkzeugnutzung eines halben Jahres gefahren wird. Durch den progressiven, abrasiven Verschleiß an den Biegestempeln wird somit bei gleicher Stempelposition eine geringere Biege Wirkung erzielt. Analog zu den anderen Störgrößen wird ebenfalls eine anhand des Gesamtmaterialabtrags äquivalente Stellgrößenänderung x_V über die Übersetzungsverhältnisse des Aktorsystems und des Teilungsverhältnisses der Stellschraube ermittelt.

Auf Basis dieser Modelle wurde das Referenzmodell erstellt und in einer Simulationsumgebung in MATLAB Simulink implementiert, welches im Folgenden eine reale Anlage darstellt. Das Referenzmodell besteht aus den bereits bekannten Stellgrößenmodellen, die die Qualitätsmerkmale berechnen. Diese werden nun von den Störgrößenmodellen beeinflusst, sodass abweichende Qualitätsmerkmale resultieren. Die Störgrößenmodelle bestehen jeweils aus einer Annahme für die Auswirkung der Störgröße auf den Biegespalt s , der Umrechnung dieser Auswirkung in eine äquivalente Stellgrößenänderung und der Berechnung der resultierenden Abweichung der Qualitätsmerkmale. Auch wenn die Annahmen für die Auswirkungen der Störgrößen auf den Biegespalt bei der Blechdicke und der Temperatur linearer Natur sind, sind die Auswirkungen auf die Qualitätsmerkmale durch die nichtlinearen Stellgrößenmodelle nichtlinear und individuell für jedes Qualitätsmerkmal




Bild 4-27: Beispiele der Auswirkungen der Temperatur auf die Qualitätsmerkmale y_1 bis y_4

wie in Abbildung 4-27 beispielhaft anhand der Auswirkungen der Temperatur zu erkennen. Im Folgenden wird das Referenzmodell verwendet, um die Nutzung des Werkzeugs über ein halbes Jahr zu simulieren und so Produktionsdaten synthetisch zu generieren, die mithilfe von ML-Verfahren in datengetriebene Modelle überführt werden.

Zur Datenerzeugung wird eine Monte-Carlo-Simulation genutzt, die synthetische Daten für die Produktion eines Halbjahres mit dem Zielwerkzeug ausgibt. Für die Produktion in dem halben Jahr wird angenommen, dass das Werkzeug alle zwei Wochen für je zwei Schichten á acht Stunden genutzt wird und die Daten persistiert werden. Hierbei stehen neben den Stellgrößen und Qualitätsmerkmalen der Produkte ebenfalls die Störgrößen zur Verfügung und können in der Simulation vorgegeben werden. Während die durchlaufenen Hübe der Maschine und damit der Verschleiß über das halbe Jahr monoton steigen bis das Werkzeug instandgesetzt wird, wird für die Temperatur und die Blechdicke jeweils eine Normalverteilung angenommen, die über die Erwartungswerte μ_T bzw. μ_d und der Standardabweichung σ_T bzw. σ_d abgebildet werden (siehe Abbildung 4-28). Bei jedem neuen




Bild 4-28: Normalverteilte Wahrscheinlichkeitsverteilung für Temperatur und Blechdicke und Gleichverteilung für den Verschleiß

Produktionstag wird vereinfachend angenommen, dass der Wahrscheinlichkeitsverteilung folgend eine Temperatur in der Produktionshalle und eine Blechdicke beim Material vorherrscht. Somit wird für jede Sicht eine Simulation mit zufälliger Störverteilung berechnet und die Merkmale der einzelnen virtuellen Produkte ermittelt und aufgezeichnet. Zusätzlich wurde in dem Modell ein an reale Messungen angelehntes Prozessrauschen integriert,

um die Schwankungen des Prozesses und das Messrauschen zu berücksichtigen.

Entwicklung des datengetriebenen Störgrößenmodells

Dieser Datensatz wurde dazu genutzt, um verschiedene ML-Modelle zu trainieren. Hierbei soll das Modell die Gesamtauswirkungen der Störungen auf das Qualitätsmerkmal vorhersagen, also der Form

$$\Delta \hat{y} = \Delta \hat{y}(T, s, k)$$

sein. Auf die Regressionsaufgabe wurden unterschiedliche ML-Algorithmen angewendet und mithilfe einer Rastersuche und der Kreuzvalidierung die einzelnen Modelle bezüglich der Hyperparameter optimiert. Hierzu wurden die Daten zufällig in Trainings- und Testdaten unterteilt und die Verteilung auf Konsistenz überprüft. Neben

- Support-Vector-Machines Regression (SVM), wurden
- künstliche neuronale Netze (ANN),
- Ensemble Trees (ET) und
- die lineare Regression (LR)

auf das Problem mit jeweils optimierten Hyperparametern angewendet. Das Ergebnis ist vergleichend in Abbildung 4-29 zu sehen. In der Grafik ist jeweils die von dem jeweiligen Algorithmus optimal parametrisierte Variante abgebildet und die mittlere quadratische Abweichung (RMSE⁷)

$$e_{RMS,j} = \sqrt{\frac{\sum_{i=1}^{n_T} (\hat{y}_{j,i} - y_{j,i})^2}{n_T}}$$

für die Testdaten abgebildet, welche hier als Auswahlkriterium herangezogen wird. Hierbei spiegelt n_T die Anzahl der Testdatensätze wider und $\hat{y}_{j,i}$ die Prädiktion für das j-te Qualitätsmerkmal und den i-ten Datensatz. In den Ergebnissen zeigt sich, dass insbesondere für die Qualitätsmerkmale y_1 und y_2 die neuronalen Netze als auch die SVM die besten Ergebnisse liefern. Werden nun noch die weiteren Qualitätsmerkmale y_3 und y_4 hinzugezogen, kristallisieren sich die neuronalen Netze für den hier betrachteten Fall als geeignetster Approximator heraus.

Als sehr gut herausgestellt hat sich hier eine Architektur des neuronalen Netzes mit dem notwendigen Input Layer mit drei, ein Hidden Layer mit acht und einem Output Layer mit den notwendigen vier Neuronen für die betrachteten Qualitätsmerkmale. Im Hidden Layer wurde als Aktivierungsfunktion die Sigmoid-Funktion, im Output-Layer eine lineare Funktion genutzt. Zur Berechnung der Gewichte des neuronalen Netzes wurde als Zielfunktion der Mean Squared Error genutzt und für die Optimierung der Levenberg-Marquardt-Algorithmus eingesetzt. Für das Training wurden 80% der Daten zufällig ausgewählt und per Kreuzvalidierung die idealen Gewichtungen berechnet. 20% der Daten wurden für den abgebildeten abschließenden Test genutzt. Die künstlichen neuronalen Netze werden aufgrund der sehr guten Ergebnisse weiter betrachtet und näher beleuchtet.

⁷RMSE: Root Mean Squared Error




Bild 4-29: Root Mean Squared Error (e_{RMS}) der betrachteten ML-Algorithmen für die berücksichtigten Qualitätsmerkmale

Die Residuenplots in Abbildung 4-30 zeigen im Überblick die berechneten Werte des Referenzmodells (y_i) über die prädizierten Werte des neuronalen Netzes ($\hat{y}_i$). Die Datenbasis für diese Grafiken sind die 20% der Testdaten, die ebenfalls für die Berechnung des mittleren Fehlerquadrats genutzt wurden. Bei der Interpretation der Abbildung ist die individuelle Skalierung der einzelnen Qualitätsmerkmale zu berücksichtigen. Mithilfe dieser Grafiken wird darauf geschlossen, dass das Approximationsverhalten des neuronalen Netzes für die Testdaten in einem hinreichend genauen Bereich liegt. Zwar wirkt die Streuung der ersten beiden Merkmale bei der ersten Betrachtung zunächst etwas höher als die der verbleibenden Qualitätsmerkmale. Mit Blick auf die Größenverhältnisse der Streuung und der Toleranz der Merkmale ist ersichtlich, dass diese in einem für das Einrichten hinreichend genauen Bereich liegt.

Während die Residuenplots eine stark aggregierte Form zur Analyse des Störgrößenmodells bietet und einen schnellen Überblick verschafft, können ebenfalls die einzelnen Verläufe der Störgrößenmodelle analysiert werden. Es ist zu beachten, dass in diesem Fall drei Eingangsgrößen auf eine Ausgangsgröße abgebildet werden und damit in grafischer Form schwer übersichtlich darstellbar sind. In Abbildung 4-31 wurde die prädizierte Auswirkung (grün) und die Referenzauswirkung (orange) auf das Qualitätsmerkmal y_1 und y_3 abgebildet. Für die jeweilig betrachtete Störgröße wurden die anderen beiden Größen




Bild 4-30: Residuenplot der Merkmale y_1 bis y_4 des künstlichen neuronalen Netzes

konstant auf ihrem Erwartungswert (μ_T, μ_d) bzw. für den Verschleiß auf den Anfangswert ($V = 0$) gesetzt. Die erste Auffälligkeit ist die unterschiedlich hohe Sensitivität der beiden Merkmale y_1 und y_3 zueinander. So wird das Merkmal y_3 deutlich stärker von den Störgrößen beeinflusst als das Längenmaß y_1 . Das Verhalten ist jedoch bereits seit der Berechnung des Stellgrößenmodells bekannt und damit konsistent hierzu. Insbesondere bei dem Qualitätsmerkmal y_1 zeigt sich, dass mithilfe der Störgrößenmodelle maximal durch eine verstärkende Auswirkung der Störgrößen auf das Merkmal der Toleranzbereich von ± 0.1 mm verlassen wird.

Ähnliches gilt für das Qualitätsmerkmal y_3 . Hier zeigt sich zunächst eine deutlich höhere Sensitivität des Merkmals bezüglich des Toleranzbereichs von $\pm 1^\circ$. Bei diesem Merkmal kann in der Regel bereits eine Störgröße mit ausreichender Intensität das Merkmal aus dem Toleranzbereich bringen. Weiterhin zeigt sich, im Gegensatz zum vorherigen Merkmal, dass in diesem Bereich die Qualitätsabweichungen für die Blechdicke und die Temperatur nahezu linearen Charakter haben. Beiden Qualitätsmerkmalen ist gemein, dass die Auswirkungen des isoliert betrachteten Verschleißes mit sehr hoher Genauigkeit approximiert werden. Demgegenüber weisen die Auswirkungen der Blechdicke und der Temperatur deutliche Abweichungen vom Referenzverhalten auf.

Die stärkeren Abweichungen des Modells sind damit zu erklären, dass diese in einem Randbereich mit geringer Datendichte ausgewertet wurden. Aufgrund der Betrachtung des Anfangszustands des Verschleißes war nur wenig Möglichkeit zur Variation für die anderen Störeinflüsse vorhanden. Somit entsteht für den Algorithmus ein schwer zu approximierendes Bild der Störeinflüsse. Dies ist bei dem späteren Funktionsnachweis zu berücksichtigen. Es zeigt sich, wie in Abbildung 4-32 zu erkennen, dass bei Betrachtung




Bild 4-31: Prädizierte (grün) und referenzielle (orange) Auswirkung der Störungen auf y_1 und y_3

eines zentraler liegenden Punktes von knapp 15% des Wartungsintervalls (also 1.2 Mio. Hübe) die Qualität des Modells deutlich gesteigert und somit der Referenzverlauf nahezu optimal mit dem künstlichen neuronalen Netz (kNN) approximiert wird.

Fazit

Es wurden in diesem Abschnitt datengetriebene Störgrößenmodelle entwickelt, die als Grundlage synthetische Daten aus einem eigens entwickelten Referenzmodell haben. Das Referenzmodell wurde zur Simulation eines halben Produktionsjahres genutzt und beinhaltet, neben dem Maschinenmodell, zusätzlich Annahmen für Störgrößenmodelle. Es konnte in diesem Abschnitt gezeigt werden, dass die verschiedenen Qualitätsmerkmale in dem Modell in unterschiedlicher Weise von den Störungen beeinflusst werden. Die Approximation des neuronalen Netzes wurde kurz beleuchtet. Aufgrund der inhomogenen Datenverteilung ist die Approximation des Randbereichs des Parameterraums ungenauer, als innerhalb. Diese Modelle können nun in die Einrichtungssystematik integriert werden, um so die notwendigen Iterationen für den Prozess zu minimieren. Dieser Funktionsnachweis wird im nächsten Abschnitt erbracht.

4.2.4 Einrichtungssystematik mit Störgrößenmodellen

Für den Funktionsnachweis der Einrichtungssystematik mit Störgrößenmodellen wird diese Strategie ebenfalls mithilfe des Referenzmodells simulativ erprobt. So wird zunächst zufällig ein Störparametersatz erzeugt und dieser dem Referenzmodell zugeführt. Anschlie-




Bild 4-32: Prädizierte (grün) und referentielle (orange, im Hintergrund) Auswirkung der Störungen auf y_1 und y_3 bei einem Verschleiß im Bereich von $1.2 \cdot 10^6$ Hüben

End werden die optimalen Startparameter berechnet, einmal allein mit dem Stellgrößenmodell und einmal mit Stell- und datengetriebenem Störgrößenmodell und so die resultierenden Qualitätsmerkmale aus dem Referenzmodell ermittelt. Eine zusätzliche Kompensation abweichender Qualitätsmerkmale findet nicht statt, da diese bereits im Vorfeld validiert wurde. Hierbei wird verglichen, inwieweit ein Vorteil bei der Berechnung der optimalen Startwerte durch die Integration der Störungen erlangt wird. Zur besseren Vergleichbarkeit der unterschiedlich ausgeprägten Qualitätsmerkmale wird die Abweichung des einzelnen Qualitätsmerkmals y_i vom Nominalwert $y_{n,i}$ mit dessen Toleranzbreite ΔT_i normiert, somit gilt für den normierten Fehler

$$e_{QM,i} = \frac{y_i - y_{n,i}}{0.5 \Delta T_i}.$$

Bei symmetrischem Toleranzbereich um den Nominalwert würde demnach eine Abweichung von 1 bedeuten, dass die obere Toleranzgrenze erreicht wird, da mit $0.5 \Delta T_i$ die halbe Toleranzbreite erfasst wird.

In Abbildung 4-33 sind die Ergebnisse von zwei verschiedenen Einrichtvorgängen bei einer definierten Störkonfiguration zu sehen. Abgebildet ist der normierte Fehler der resultierenden Qualitätsmerkmale bei einer leicht erhöhten Umgebungstemperatur, einer durchschnittlichen Blechdicke und einem fortgeschrittenem Verschleiß. Die Balkenhöhe gibt den verbleibenden normierten Fehler der einzelnen Qualitätsmerkmale ($y_1, \dots, y_4$) nach der Berechnung initialer Startparameter an - eine Kompensation hat nicht stattgefunden. Der erste Einrichtvorgang (grün) wurde dabei nur mit dem Stellgrößenmodell durchgeführt, der zweite simulierte Einrichtvorgang mit den zusätzlichen Störgrößenmodellen.

Die Ergebnisse entsprechen dabei den Erwartungen. Zunächst ist auffällig, dass die Stö-




Bild 4-33: Vergleich simulierter Einrichtprozesse mit (orange) und ohne (grün) Störgrößenmodelle mit der Störkonfiguration

rungen auf die Startwertberechnung ohne Störgrößenmodelle (grün) den erwarteten negativen Effekt aufweisen. Die Qualitätsmerkmale sind zum Teil sehr nah an der Toleranzgrenze und übertreten diese sogar (siehe Qualitätsmerkmal y_3). Bei der Berechnung der Startwerte unter Berücksichtigung der Störgrößenmodelle (orange) ergibt sich in diesem Fall ein gemischtes Bild. So hat sich das Qualitätsmerkmal y_1 etwas weiter verschlechtert, wohingegen sich die anderen Merkmale verbessert (y_2) oder auch deutlich verbessert (y_3, y_4) haben. Die Optimierung hat die Konfiguration als den bestmöglichen Kompromiss zwischen den verschiedenen Qualitätsmerkmalen berechnet. Es zeigt sich zusätzlich noch ein Effekt, der bereits in den früheren Kapiteln (siehe Abschnitt 4.2.1) aufgefallen ist: während die ersten beiden Qualitätsmerkmale (y_1, y_2) eine geringe Sensitivität bezüglich der Stellschrauben aufweisen, lassen sich die anderen beiden Qualitätsmerkmale (y_3, y_4) in einem deutlich größeren Bereich verstellen, sodass sich auch anliegende Störungen leichter ausgleichen lassen. Demgegenüber steht aber auch ein deutlich schwierigeres manuelles Finden der optimalen Einstellungen. Mithilfe der Optimierung ist es möglich, die zuletzt genannten Qualitätsmerkmale nahezu ohne verbleibendem Fehler einzurichten.

In Abbildung 4-34 ist eine weitere Störkonfiguration und deren resultierender verbleibender Fehler nach der Berechnung der Startwerte illustriert. Die Störkonfiguration ergibt sich aus einer höheren Umgebungstemperatur, einer deutlich geringeren Blechdicke und einem fortgeschrittenen Verschleiß. Auch mit dieser Konfiguration bestätigten sich die Aussagen aus dem vorherigen Test. Zusätzlich wird hier deutlich, dass auch größere Abweichungen eines Qualitätsmerkmals (y_3, y_4) entstehen können, die durch eine genauere Kenntnis der Störungen bereits bei der initialen Einrichtiteration eliminiert werden können. Bei dieser Störkonfiguration ist das Systemverhalten signifikant unterschiedlich zum




Bild 4-34: Vergleich eines zweiten simulierten Einrichtprozesses mit einer definierten Störkonfiguration mit (orange) und ohne (grün) Störgrößenmodelle

berechneten Modell und somit differieren die initialen Startwerte ohne den Einbezug der Störgrößenmodelle deutlich vom aktuellen Optimum: resultierend sind die Qualitätsmerkmale ebenfalls weit außerhalb des tolerierbaren Bereichs. Insgesamt wurden somit sehr gute Einstellungen in einem Schritt gefunden. Insbesondere bei preisintensiven Produkten stellt dies einen wirtschaftlichen Vorteil dar.

In Abbildung 4-35 wurden nach gleichem Schema wie in den vorherigen beiden Einrichtsimulationen weitere zehn Störkonfigurationen zufällig ausgewählt und die resultierenden Qualitätsmerkmale abgebildet. In den Versuchen wird eine Störintensität berechnet, die in unterschiedlicher Ausprägung auf die verschiedenen Merkmale wirkt. Diese variiert über die verschiedenen durchgeführten Versuche. Zusätzlich zeigt sich, dass analog zu den vorherigen beiden Simulationen, die Streuung im Allgemeinen bei den Qualitätsmerkmalen y_1 und y_2 deutlich geringer ist als bei den anderen beiden Qualitätsmerkmalen. Aufgrund der geringen Sensitivität der ersten beiden Qualitätsmerkmale bezüglich der Stellschrauben und einem notwendigen Kompromiss bei der Einstellung der Stellschrauben, ist eine Reduktion des Fehlers für die Qualitätsmerkmale y_1 und y_2 kaum möglich. Demgegenüber stehen die Qualitätsmerkmale y_3 und y_4 , die nahezu optimal auf ihren Sollwert eingestellt werden können.

4.3 Bewertung der Ergebnisse

In diesem Kapitel wurde die in Kapitel 3 entwickelte Systematik mit der Referenzarchitektur, also den vorgeschlagenen Algorithmen zur Berechnung der Startwerte für das




Bild 4-35: Vergleich der Startwertberechnung für zehn verschiedene Störkonfigurationen

Einrichten und der Kompensationsstrategie anhand eines Beispiels validiert. Nach einer Analyse des Zielsystems, einem FVP, wurde zunächst mithilfe der statistischen Versuchsplanung und der RSM ein Modell des Stellgrößenverhaltens berechnet. Dieses bildet die Auswirkungen der Stellgrößen auf die Qualitätsmerkmale ab. Bei dem Modell hat sich gezeigt, dass deutlich mehr und auch nichtlineare Einflüsse der Stellgrößen auf die Qualitätsmerkmale existieren als zuvor während der Analysephase mit Experten angenommen. Zusätzlich hat sich gezeigt, dass sich die Qualitätsmerkmale bezüglich ihrer Sensitivität deutlich unterscheiden. Während die Längen (Qualitätsmerkmale $\hat{y}_1$ und $\hat{y}_2$) ein robustes Verhalten zeigen, sind die Winkel deutlich anfälliger für Änderungen. Das Modell für den zweiten Winkel ($\hat{y}_4$) zeigt hier aufgrund der unsicheren Messung eine höhere Abweichung als sein Pendant, dem Winkel $\hat{y}_3$. Weiterhin wurde dargestellt, dass die vorhandenen nichtlinearen Effekte eine geringere Ausprägung als die linearen Effekte haben. Es kann festgehalten werden, dass diese nichtlinearen Effekte insbesondere bei Präzisionsanwendungen und -produkten in ihrer Bedeutung zunehmen. Die Stellgrößenmodelle wurden abschließend mithilfe zusätzlicher Messungen validiert. Für zukünftige Applikationen ist dieses Modell das extrahierte Expertenwissen, welches bereits beim Produktionsstart verfügbar ist. Das Wissen über die Auswirkungen der Störungen ist zu diesem Zeitpunkt noch nicht vorhanden.

Im Anschluss daran wurde dieses Modell genutzt, um das Einrichtungskonzept für einen Testproduktionsstart des Produkts an der physischen Produktionsanlage zu validieren. Hierzu wurde das Modell in die toleranzbasiert gewichteten Mehrzieloptimierung integriert und die initialen Startparameter über die definierte Zielfunktion berechnet. Hierbei zeigte sich, dass sich die berechneten Werte zunächst kaum von den bereits vorhandenen Produkti-

onsparametern unterschieden. Da diese bereits erfolgreich zur Herstellung von Produkten verwendet wurden, ist dies ein sehr guter Indikator für die erfolgreiche Implementierung der Optimierung, inklusive Modelle und toleranzbasiert gewichteter Zielfunktion.

Im nächsten Schritt wurde dann die Kompensation der Störungen durchgeführt. Da in diesem Schritt die Auswirkungen der messbaren Störungen noch nicht bekannt sind, werden diese zusätzlich zu den nicht-messbaren Störungen kompensiert. Aufgrund der bereits sehr guten Startwerte, war nur noch eine geringe Kompensation notwendig, die ebenfalls sehr erfolgreich berechnet werden konnte. Beim Testen der Systematik in der Produktion hat sich gezeigt, dass beim konventionellen Einrichten schnell Fehler bezüglich Betrag und Richtung der Kompensation passieren und viel Wissen vom Bediener erfordert. Aufgrund der mechanischen Ausführung des Prozesses sind die Fehler zwar auch bei dem assistierten Einrichten nicht ausgeschlossen, durch die verbesserte Unterstützung des Bedieners konnten diese jedoch deutlich abgeschwächt werden.

Es ist festzuhalten, dass sowohl die Erstellung der Modelle mithilfe der RSM, sowie die entwickelte Optimierung zur Berechnung der Startwerte, als auch der Kompensation sehr gut funktioniert. Funktionsfähige, initiale Prozesseinstellungen werden mithilfe der Optimierung zuverlässig gefunden, es zeigte sich jedoch auch, dass insbesondere durch vorhandene Störungen noch Verbesserungspotential besteht. Bei niedrigpreisigen Produkten ist die initiale Abweichung der Qualitätsmerkmale und die anschließende Kompensation der Störungen eine gute Variante, bei hochpreisigen, komplexeren Produkten ist die Motivation, eine direkt optimale Einstellung zu finden, ausgeprägter. Insbesondere für letztere Produktgruppe wurde in der Systematik die Möglichkeit für das kontinuierliche Lernen vorgesehen, indem zusätzliche Daten für die Störungen und die Abweichung der Qualitätsmerkmale gesammelt und ausgewertet werden.

Das so erweiterte Konzept wurde im Gegensatz zur vorherigen Variante simulativ verifiziert, da die notwendige Sensorik an dem Beispielprozess nicht vorhanden ist und eine Modifikation des Werkzeugs aus betrieblichen und wirtschaftlichen Gründen ausgeschlossen war. Aus diesem Grund wurden die Stellgrößenmodelle um Störgrößenmodelle zur Blechdicke, Temperatur und Verschleiß erweitert und mithilfe eines Referenzmodells synthetisch Produktionsdaten erzeugt. Diese Daten wurden mithilfe verschiedener Lernalgorithmen approximiert und der für diese Anwendung beste Algorithmus, künstliche neuronale Netze, für die weitere Anwendung ausgewählt. Nun wurden verschiedene Einrichtungsituationen mit unterschiedlichen Störeinflüssen simuliert und entsprechend der in dieser Arbeit vorgeschlagenen Strategie vorgegangen. Es zeigt sich, dass ein genaueres Verständnis des Prozesses mithilfe umfangreicherer Modelle einen sehr positiven Effekt auf die Genauigkeit der initialen Stellgrößenprädiktion hat und demzufolge insbesondere bei höherpreisigen Produkten dieser Aufwand lohnenswert ist. Eine umfangreiche Datensammlung, welche ebenfalls die Variabilität dieser messbaren Störungen gut erfasst, ist notwendig. So schwanken Temperaturen möglicherweise saisonal und Blechdicken oder -eigenschaften lieferantenabhängig. Diese Erkenntnis bekräftigt zusätzlich die Design-Entscheidung für das Einrichten zwischen kontrollierbaren und nicht-kontrollierbaren Stellgrößen zu unterscheiden und eine Vorstufe zu implementieren, um bereits im frühen Produktionsstadium diesen komplexen Prozess unterstützen zu können.

Bewertung der Anforderungserfüllung

Zu Beginn dieser Arbeit wurden in Kapitel 3 verschiedene Anforderungen identifiziert, die für das System relevant sind, um in der Produktionsumgebung erfolgreich eingesetzt werden zu können. Es wurde definiert, dass das entwickelte System keine Insellösung für eine Prozessgruppe sein soll, sondern die **Übertragbarkeit** gewährleistet sein muss: auch auf weitere Prozessarten. Dies konnte bereits in dem hier betrachteten Anwendungsbeispiel aufgrund der ausgewählten Methoden nachgewiesen werden. So wurden für die Anwendung die RSM für Stellgrößen und ML-Verfahren für Störgrößen verwendet und die ebenfalls allgemein vorgeschlagenen Strategien für die Berechnung der Startwerte und die Störkompensation genutzt. Ein weiteres Kriterium war die **Flexibilität**, die anhand des FVP gut dargestellt werden konnte. Aufgrund der mechanischen Ausprägung der Prozessaktorik wurde ein manueller Eingriff in das System vorgenommen und eine automatisierte Qualitätsermittlung integriert. Hier hat sich ebenfalls bestätigt, dass aufgrund der heterogenen Produktionslandschaft eine weitere spezifische Ausdetaillierung der Schnittstellen nicht zielführend ist. Die Systematik stellt eine einfache **Bedienbarkeit** der implementierten Modelle und Algorithmen sicher. In ähnlicher Form könnte diese auf zentralen Servern zur Verfügung gestellt werden, um ortsunabhängig auf die Daten und Berechnungsergebnisse zugreifen zu können. Dies setzt natürlich eine entsprechend vernetzte Produktion voraus, die bei dem betrachteten FVP und auch in den meisten produzierenden Unternehmen zum jetzigen Zeitpunkt noch nicht gegeben ist. Aber auch dieses Zukunftsszenario kann mithilfe der Systematik abgebildet werden.




Bild 4-36: Erfüllung der Anforderungen an das Einrichtsystem

Bezüglich der **Konfigurierbarkeit** des Zielsystems, wurde bei der Entwicklung der Systematik darauf geachtet, dass diese auch mit einer höheren Anzahl an Einflussgrößen zurecht kommt. Dies konnte ebenfalls mit der Validierung am Beispielprozess nachgewiesen werden: das Vorgehen zur Reduktion der Versuche und Einflussgrößen war erfolgreich und hat die Entwicklung des EAS unterstützt sowie die **Effizienz** des zweischrittigen Ansatzes aufgezeigt. Auch die prognostizierte **Robustheit** gegenüber Modell-

ungenauigkeiten konnte nachgewiesen werden. Es wurde gezeigt, dass die unbekannten Einflüsse in der Startwertberechnung Auswirkungen zeigen, diese aber insbesondere durch die Störkompensation eliminiert werden: das EAS reagiert so gegenüber den unbekannten Einflüssen robust. Es muss jedoch berücksichtigt werden, dass sich Störungen zum Teil verstärken können und in einigen Fällen die Grenzen der Stellgrößen erreicht werden können. Dies ist kein Spezifikum des EAS, sondern eine generelle Herausforderung für Produktionsprozesse. Aufgrund der Systematik wird diese in dem betrachteten Fall jedoch deutlicher. Mithilfe der langfristigen Berücksichtigung der nicht-kontrollierbaren Einflussgrößen lernt das System stetig hinzu und verbessert die Prognosefähigkeit der Qualitätsmerkmale, womit ebenfalls die **Lernfähigkeit** aufgezeigt und implementiert wurde.

Die Beispielapplikation hat gezeigt, dass die entwickelte Systematik für das Einrichten einen sinnvollen Rahmen bietet, um den Einrichtprozess komplexer Produktionsprozesse zu systematisieren. Die zuvor prognostizierte Erfüllung der Anforderungen wurde anhand des Beispielprozesses nachgewiesen. Die explizite Unterscheidung zwischen kontrollierbaren und nicht-kontrollierbaren Einflussgrößen für das EAS hat den Vorteil, dass das System in einem zweischrittigen Verfahren in die Produktion integriert werden kann und bereits von Beginn an für die Bediener Unterstützung bietet. Aufgrund der mechanisch geprägten Beschaffenheit des betrachteten Prozesses wurden in dem Anwendungsbeispiel einige Prozessschritte manuell durchgeführt, die bei höher automatisierten Prozessen durch regelbare Prozesseingriffe substituiert werden können. Für diese kann die hier beschriebene Systematik ebenfalls den notwendigen Input liefern.

5 Zusammenfassung und Ausblick

Nachdem im vorherigen Kapitel die entwickelte Einrichtsystematik anhand eines Beispielprozesses erfolgreich validiert wurde, wird folgend eine abschließende Zusammenfassung der vorliegenden Arbeit und ein Ausblick auf weitere mögliche Forschungsarbeiten gegeben.

5.1 Zusammenfassung

Die Arbeit ist im Produktionsbereich situiert und befasst sich mit dem Einrichten der Produktionsprozesse. Das Einrichten von Produktionsprozessen befasst sich mit dem Finden optimaler Einstellungen für einen Produktionsprozess. Es findet sowohl bei der initialen Inbetriebnahme des Prozesses, als auch bei der Wiederaufnahme der Produktion eines Produkts statt. Das Ziel der Arbeit ist, das Vorgehen zu systematisieren, um die Qualität und die Effizienz dieser Tätigkeit zu maximieren.

Hierfür wurde zunächst der Stand der Technik ausgearbeitet und im ersten Schritt die verschiedenen Produktionsprozesse nach DIN 8580 in Kategorien unterteilt. Hier zeigte sich die hohe Diversität der verschiedenen Produktionsprozesse, deren Gemeinsamkeit die Nutzungsmöglichkeit unterschiedlicher Prozessparameter ist. Nachfolgend wurden die verschiedenen Automatisierungsgrade der Produktion, analog zu den Stufen des autonomen Fahrens, vorgestellt. Hierbei wurden in der Literatur 6 Stufen definiert, die jeweils eine unterschiedlich ausgeprägte Automatisierung aufweisen. Von der Stufe 0, rein gesteuerte Prozesse, über Stufe 2, der Regelung von Prozessgrößen und Stufe 3, der Regelung von Qualitätsmerkmalen, bis zu Stufe 5 einer selbstoptimierenden, selbstlernenden Produktion. Anhand aktueller Forschungsarbeiten wurde der Schluss gezogen, dass nur in wenigen Fällen in der Praxis die Stufe 3 erreicht wird. In den meisten Fällen findet keine Regelung der Qualitätsmerkmale eines Produkts statt. Daher nehmen auch nach wie vor die Maschinenbediener einen wichtigen Platz in der Produktion ein: sie rüsten die Maschine, berücksichtigen die Systemgrenzen, überwachen den Prozess und die Produktqualität während des Produktionsbetriebs und ergreifen Maßnahmen, um korrigierend einzugreifen.




Bild 5-1: Anteil der Einrichtzeit an der Maschinennutzung

Das Rsten stellt dabei eine wesentliche Aufgabe der Maschinenbediener dar und liefert einen signifikanten Beitrag fr die resultierende Produktqualitt. Daher wurde im nchsten Schritt der Rstprozess nher betrachtet und analysiert. Es hat sich anhand der Literatur gezeigt, dass der Rstprozess bereits in vielen Verffentlichungen Optimierungsgegenstand war. Eine der verbreitetsten Methoden ist das SMED-Verfahren (Single Minute Exchange of Die), welches durch eine Separation von in- und externen Rstttigkeiten den Maschinenstillstand reduziert. Im Zuge dieser Methode hat sich besttigt, dass das Einrichten einen wesentlichen Teil der Aufwnde beim Rsten generiert (siehe Abbildung 5-1). Daher wurde im Anschluss daran der Einrichtprozess nher untersucht, sowie die Analogie zur Regelungstechnik aufgezeigt. Darauf aufbauend wurden verschiedene, hufig prototypische Anstze fr das Finden optimaler Maschinenparameter vorgestellt, die im Rahmen von Forschungsprojekten entwickelt wurden. Hier hat sich gezeigt, dass die Anwendungen hufig fr eine einmalige Ausfhrung ausgelegt sind, das Einrichten aber ein wiederkehrender Prozess ist (siehe Abbildung 5-2). Ein weiteres Problem ist, dass ein zeitinvariantes Verhalten des Systems postuliert wird und so vernderliche Strungen keine Anwendung finden. Es wurde der Schluss gezogen, dass Assistenzsysteme ein Ansatz sind, um auch bei flexibler Produktion und kleinen Losgren die Einrichtaufwnde auf einem wirtschaftlichen Niveau zu halten. Daher wurden im nchsten Schritt bereits vorhandene, kontextnahe Assistenzsysteme in der Produktion errtert.




Bild 5-2: Schema des Einrichtprozesses - nach [GSH⁺ 18]

Hierfr wurden verschiedene Sichten auf die Assistenzsysteme eingenommen und analysiert. So wurden Kategorisierungen aus Sicht der Arbeitsgestaltung, Logistik und Produktionsprozesse betrachtet und die einzelnen Schwerpunkte herausgearbeitet, um einen berblick ber mgliche Ausprgungen der Assistenzsysteme zu geben. Anschließend wurden vorhandene Assistenzsysteme insbesondere aus dem Forschungskontext errtert und dargelegt, in welchem Bereich noch Forschungsbedarf besteht. Es hat sich gezeigt, dass in den bereits vorhandenen Anwendungen vor allem bereits vorhandenes Expertenwissen nutzerfreundlich fr einen spezifischen Prozess aufbereitet wird, wobei ein Fokus auf qualitatives und nicht quantitatives Wissen gelegt wird und Strungen im Einrichtprozess noch keine Bercksichtigung finden. Grundlage fr die betrachteten Systeme sind in der Regel Reprsentationen des Produktionsprozesses, welche auf Basis von Expertenwissen und Prozessdaten entwickelt werden.

Fr diese Arbeit wurden im Anschluss die datengetriebenen Verfahren zur Modellbildung errtert. Hierbei wurde zum einen das klassische Verfahren, die RSM, vorgestellt. Die Methode besteht aus der statistischen Versuchsplanung, einer Regressionsanalyse und

einer Varianzanalyse, um die Auswirkungen von Einflüssen und Qualitätsmerkmalen zu untersuchen. Der Vorteil dieser Methode ist ein geringer Versuchsumfang bei maximaler Aussagekraft, um zu einem statistisch abgesicherten Modell zu gelangen. Aufbauend darauf wurden verschiedene Anwendungen aus der Wissenschaft skizziert, um die üblichen Zielsetzungen dieser Methoden aufzuzeigen. Häufig wird die RSM zur Parameteroptimierung für Prozesse genutzt. Allerdings finden sich hier vorwiegend einmalige Anwendungen wieder: der Umgang mit Störungen und eine wiederkehrende Anwendung, wie sie beim Einrichten notwendig ist, werden nicht thematisiert. Aufgrund der zunehmenden Speicher- und Rechenkapazitäten wird der Einsatz der Methoden des maschinellen Lernens auch für die Produktion ermöglicht, sodass auch diese im Anschluss grundlegend vorgestellt wurden. Basierend auf einem Vorgehensmodell wurden Lernaufgaben (Klassifikation, Regression und Clustering) und Lernstile (zum Beispiel überwachtes, unbeaufsichtigtes, bestärkendes Lernen) vorgestellt. Anschließend wurde auch ein kontextnaher Überblick über verschiedene Anwendungen gegeben. Zusätzlich wurden auch Kombinationen der statistischen Versuchsplanung und maschineller Lernverfahren dargestellt. Es wurde der Schluss gezogen, dass sich die datengetriebenen Anwendungen je nach Datengrundlage bereits etabliert haben. Einschränkend festzuhalten ist, dass auch bei den maschinellen Lernverfahren häufig einmalige Anwendungen fokussiert werden und nicht-messbare Störungen keine Berücksichtigung finden. Das Einrichten und die Kompensation von Qualitätsabweichungen ist auch heute noch in der Verantwortung der Maschinenbediener.

Aus dem Stand der Technik wird abgeleitet, dass eine Systematisierung von Einrichtungsassistenzsystemen benötigt wird, um auch in Zukunft für die teilautomatisierten Prozesse einen flexiblen und wirtschaftlichen Betrieb zu ermöglichen. Diese Systeme haben das Potenzial die Bediener weitreichend zu unterstützen und durch eine strukturierte Vorgehensweise die Qualität in einer immer komplexer werdenden Produktion sicherzustellen. Hierfür wird eine Systematik benötigt, welche eine einfache Nutzung für die vielfältigen Produktionsprozesse ermöglicht. Weiterhin sollen sowohl messbare, also auch nicht-messbare Störungen in dem System berücksichtigt werden, um die Arbeit der Bediener zu unterstützen.

Basierend auf dem Stand der Technik wurde in Kapitel 3 eine Systematik für Einrichtungsassistenzsysteme nach den identifizierten Forschungsfragen entwickelt. Hierbei wurde zunächst eine Klassifikationssystematik für Assistenzsysteme in der Produktion entwickelt, um zum einen die wesentlichen Systemkomponenten zu identifizieren und zum anderen eine bessere Charakterisierung zu ermöglichen. Hierbei wurden die bereits erörterten Klassifikationen zusammengeführt und erweitert. Zusätzlich wurden die Rahmenbedingungen für ein solches System analysiert und darauf aufbauend eine Referenzarchitektur (siehe Abbildung 5-3) entwickelt. Bei der Referenzarchitektur wurden wesentliche Module identifiziert und theoretisch ausgearbeitet. Die Systematik für das EAS basiert auf einem zweigeteilten Modell, welches das Stell- und das Störgrößenverhalten abbildet. Die Idee ist, dass das Stellgrößenverhalten mithilfe der RSM abgebildet wird, welche die statistische Versuchsplanung, sowie eine Regressions- und Varianzanalyse umfasst. Dies ist aufgrund der Kontrollierbarkeit dieser Einflüsse möglich. Demgegenüber steht das Störgrößenmodell, welches aufgrund der zu erwartenden deutlich größeren Datenmenge mithilfe maschineller Lernverfahren approximiert wird. Das größere Datenvolumen ist mit der geringeren Variabilität der nicht-kontrollierbaren Störungen begründet:




Bild 5-3: Referenzarchitektur der Systematik für das EAS

das Produktionssystem muss über eine längere Zeit beobachtet werden, um die notwendigen Korrelationen aufzudecken.

Mithilfe dieser sukzessiv erstellbaren Modelle der Anlage wurden anschließend die beiden Module der Startwertberechnung und der Kompensationsstrategie vorgestellt. Hierfür wurde eine toleranzbasierte Zielfunktion vorgestellt, die als gewichtete Summe der quadratischen Abweichung des Modells vom Nominalwert der Qualitätsmerkmale ausgeführt ist. Das Modell kann hierbei entweder nur das Stellgrößenmodell sein oder ebenfalls das Störgrößenmodell inkludieren. Die Gewichte der einzelnen Summanden werden dabei mithilfe der Toleranzbreite der einzelnen Qualitätsmerkmale definiert. Basierend auf der Zielfunktion wurde so ein Optimierungsproblem unter Berücksichtigung der Prozessgrenzen formuliert, welches mit einem Optimierer gelöst werden kann. Die so berechneten Einstellungen werden dem Bediener als Empfehlung kommuniziert und anschließend die resultierende Qualität beurteilt. Da sich Produktionsprozesse verändern können oder nicht-messbare Störungen Auswirkungen auf die Produktqualität haben können, wird die Möglichkeit der Störkompensation vorgesehen. Diese basiert ebenfalls auf einem Optimierungsproblem, welches die momentan ermittelten Abweichungen vom Nominalzustand berücksichtigt. Den Abschluss des Kapitels bildet die Erörterung der Vorgehensweise für die Systematik und die Bewertung der Anforderungserfüllung, welche zusammenfassend in Abbildung 5-4 abgebildet ist.

Nach der Entwicklung und Bewertung der Systematik wurde diese anhand eines Beispielprozesses in Kapitel 4 validiert. Hier wurden zunächst der Produktionsprozess, ein Folgeverbundprozess, vorgestellt und die wesentlichen Einflussgrößen und Qualitätsmerkmale des Produkts mithilfe von Experteninterviews herausgearbeitet. Der Folgeverbundprozess wird über mehrere mechanische Stellschrauben an die aktuellen Umweltbedingungen angepasst und die Qualität mithilfe eines Kamerasystems erfasst. Nach der Abschätzung des notwendigen Stichprobenumfangs wurden Vorversuche an dem Prozess durchgeführt, um die signifikanten Merkmale mithilfe einer geringen Versuchsanzahl zu bestätigen. Mit-




Bild 5-4: Erfüllung der Anforderungen an das Einrichtsystem

hilfe dieser Vorversuche konnten zum einen Justagestellen für die weitere Betrachtung ausgeschlossen werden und zum anderen die für die Betrachtung wesentlichen Qualitätsmerkmale identifiziert werden. Dies ist hilfreich, um den Versuchsumfang auf ein Minimum zu beschränken. Im Anschluss an die Analyse der Stellgrößen wurden zusätzlich die wesentlichen, messbaren Störgrößen mithilfe der 5M-Methode identifiziert. Das Ergebnis war, dass die Störgrößen Umgebungstemperatur, Zeitpunkt seit der letzten Wartung und Blechdicke berücksichtigt werden sollen.

Nach der Analyse des Prozesses wurde die entwickelte Architektur der Systematik angewendet. So wurde zunächst das Stellgrößenmodell berechnet, indem ein Central-Composite Design auf die signifikanten Stellgrößen (hier Stellschrauben) angewendet und mithilfe einer Regressions- und abschließender Varianzanalyse ausgewertet wurde. Das Resultat war ein statistisch abgesichertes Stellgrößenmodell. Nach der Validierung des Modells mithilfe zusätzlicher Messungen wurde die Einrichtungstrategie validiert. Das Stellgrößenmodell wurde in der Optimierung genutzt, um ideale Stellgrößenkonfigurationen zu berechnen und diese an den Bediener als Empfehlung auszugeben. Hier hat sich gezeigt, dass diese sehr ähnlich zu den Einstellungen waren, die bereits von einem erfahrenen Maschinenbediener genutzt wurden. Die gewählte Zielfunktion der Systematik entspricht der intuitiven Priorisierung eines erfahrenen Maschinenbedieners: ein sehr zufriedenstellendes Ergebnis. Eine Analyse der Qualitätsmerkmale hat gezeigt, dass diese noch Optimierungspotenzial aufweisen. Aus diesem Grund wurde das Stellgrößenmodell mit der Kompensationsstrategie genutzt, um die Einstellungen für eine optimale Produktqualität zu berechnen. Auch hier hat sich gezeigt, dass die Strategie sehr gute Handlungsvorschläge unterbreitet, um zu sehr guten Qualitätsmerkmalen zu gelangen.

Es ist offensichtlich, dass jede Iteration bei dem Einrichten im Produktionsbetrieb bei komplexen Produkten aufgrund von hohen Kosten zu vermeiden ist. Daher kann es sinnvoll sein, die im vorherigen Schritt in der Kompensation berücksichtigten Störungen bereits bei der Startwertberechnung zu integrieren, sofern sie messbar sind. Für die Erstellung der Störgrößenmodelle werden die Einflüsse der Störungen auf die Qualitätsmerk-

male benötigt. Um ein solches Zukunftsszenario einer digitalen Produktion zu untersuchen, wurde das Konzept in dieser Arbeit mithilfe einer Simulation verifiziert. Hierzu wurden in das Stellgrößenmodell die Störgrößen zusätzlich implementiert und mithilfe dieses Referenzmodells eine Produktion eines Produktes über ein halbes Jahr simuliert und synthetisch Daten erzeugt. Diese Daten wurden genutzt, um die Abweichung der Qualitätsmerkmale von den vom Modell ermittelten Qualitätsmerkmalen zu berechnen. So konnten mithilfe maschineller Lernverfahren die Störgrößen mit diesen Qualitätsabweichungen korreliert werden, um die Störgrößenmodelle zu erstellen. Als besten Approximator wurde ein flaches künstliches neuronales Netz identifiziert. Im Anschluss daran wurde erneut die Berechnung der Starteinstellungen für mehrere unterschiedliche Störkonfigurationen durchgeführt und mit der Startwertberechnung ohne Störgrößenmodell verglichen. Es hat sich gezeigt, dass bei ausreichend guter Datenlage durch die implementierten Störungen ebenfalls die initiale Einrichtqualität deutlich steigt. Dies entspricht dem intuitiven Verhalten: eine Kenntnis des Prozesses resultiert in einer höheren Prädiktionsgenauigkeit.

Abschließend sei festgehalten, dass die in dieser Arbeit entwickelte Systematik für das Einrichten von Produktionsprozessen erfolgreich validiert wurde. Es hat sich gezeigt, dass eine quantitative Bedienerunterstützung insbesondere bei komplexen Produktionsprozessen Zeit- und Geld sparen kann und ebenfalls zu qualitativ hochwertigeren Produkten führt. Das Ergebnis ist eine flexibel einsetzbare Systematik, welche in der heterogenen Produktionslandschaft auf vielfältige Prozesse angewendet werden kann.

5.2 Ausblick

Auch wenn das Einrichten von Produktionsprozessen schon seit Beginn der Industrialisierung eine Aufgabe in der Produktion ist, existiert noch vielfältiges Optimierungspotential. Diese Arbeit bietet einen Ansatz für eine Systematisierung dieser notwendigen, aber nicht wertschöpfenden Aufgabe. Im Folgenden werden noch weitere Forschungsaspekte aber auch weitere Aspekte aus der angewandten Forschung erörtert, die im Anschluss an diese Arbeit in dem Themenbereich untersucht werden sollten.

Die Weiterentwicklung der heutigen Produktion zu einer „datengetriebenen Produktion“ ist ein wesentlicher Aspekt, um die gesamte vorgestellte Einrichtsystematik zu nutzen. Damit ist gemeint, dass die wesentlichen Systemgrößen eines Produktionsprozesses nicht nur erfasst, sondern ebenfalls persistiert werden, um diese für die Generierung der Störgrößenmodelle nutzen zu können. Hierbei sind noch viele Facetten zu erforschen, da für die heterogenen Anwendungen ebenfalls vielfältige Messgrößen unter zum Teil schwierigen Bedingungen erfasst werden müssen. Am Beispiel der Folgeverbundprozesse sind dies die Stellschraubeneinstellungen, die präzise erfasst werden müssen, mit einer Sensorik, die auch starke Erschütterungen langfristig aushält.

Neben der Erfassung der Systemgrößen spielt auch die Ermittlung der Produktqualität eine große Rolle, die zukünftig noch weiter erforscht und ausgebaut werden muss. Auch hier ist die anzuwendende Sensorik ein großes Feld, welche die verschiedenen Qualitätsmerkmale der vielzähligen Produkte detektieren muss. Beispiele hierfür sind geometrische Merkmale, Materialkenngrößen (wie Festigkeit, Härte, Martensitanteil) oder resultierende Prozessfehler (wie Risse, Überlappungen, Abplatzungen). Zusätzlich besteht

eine weitere Herausforderung in der inline-Messung dieser Qualitätsmerkmale, um die Aufwände für die Maschinenbediener möglichst gering zu halten. Hierbei ist auch eine Fragestellung, aus welchen Eigenschaften sich „die Qualität“ eines Produktes genau zusammensetzt und wie diese untereinander gewichtet werden. In dieser Arbeit wurde mithilfe der toleranzbasierten Gewichtung ein nachweislich guter Ansatz geliefert.

Werden diese Größen erfasst und persistiert, ist die automatisierte Auswertung dieser anfallenden Daten ein weiteres Ziel. So ist ein weiteres Forschungsfeld zum einen die automatisierte Erstellung der Stellgrößenmodelle als auch die automatisierte Generierung der Störgrößenmodelle. Bei den ersteren ist als Ziel eine autonome Versuchsdurchführung und Auswertung denkbar, die nur noch durch den Bediener überwacht und bestätigt wird. Bei letzterem müssen die Störgrößenmodelle regelmäßig auf Korrektheit geprüft und ggf. die Modelle neu trainiert werden, um aktuelle Veränderungen der Anlagen zu berücksichtigen. Hierbei ist auch eine interessante, noch zu erforschende Fragestellung, welche Daten berücksichtigt werden müssen. Hierbei wird anhand prozessspezifischer Kriterien analysiert werden müssen, welche Daten in das Training mit welcher Gewichtung einfließen. Auch die Übertragung der trainierten Störgrößenmodelle auf ähnliche Prozesse stellt ein interessantes weiteres Forschungsfeld dar. Eine Forschungsfrage ist daher, nach welchen Kriterien eine Übertragung auf weitere Prozesse möglich ist.

Neben den datengetriebenen Ansätzen können natürlich auch physikalische Modelle einen wesentlichen Beitrag zum Einrichten leisten, der noch weiter erforscht werden muss. Hier spielt das Konzept des „digitalen Zwillings“ ein, welcher unter anderem als virtuelle Gesamtrepräsentation eines Systems mithilfe von Modellen interpretiert werden kann [KKT⁺18; SBS⁺19]. Hierbei stellt sich die Frage, wie die Prozesse bereits während der Entwicklung so holistisch abgebildet werden können, dass die entsprechenden Modelle für das Einrichten genutzt werden können. Heute werden die Modelle in der Regel für Teilaspekte eines Produktionsprozesses genutzt. Ganzheitliche Modelle, die den Prozess bis auf die resultierende Qualität abbilden, existieren nur in absoluten Ausnahmefällen. Diese Modelle müssen sich natürlich trotzdem auch mit dem Produktionsprozess weiterentwickeln. Die entstehenden Daten (manchmal „digitaler Schatten“ [SEB⁺19] genannt) müssen dann zum Modell zurückgeführt werden und dieses muss sich dementsprechend adaptieren, sodass stets ein aktualisiertes Modell auch für das Einrichten zur Verfügung steht.

In der Arbeit konnte eine Systematik für Einrichtprozesse erfolgreich entwickelt und praktisch validiert werden. Es hat sich gezeigt, dass ein solches Vorgehen die Komplexität für den Maschinenbediener bei der Einrichtung deutlich reduziert und die notwendige Produktqualität zielgerichtet eingestellt werden kann. Langwierige Iterationen werden so vermieden. Aufgrund des allgemeinen Ansatzes kann die Systematik sehr gut auf weitere Prozesse übertragen werden.

Literatur

- [AA13] AIZED, T.; AMJAD, M.: Quality improvement of deep-hole drilling process of AISI D2. *The International Journal of Advanced Manufacturing Technology* 69 (2013), Nr. 9-12, S. 2493–2503
- [AA19] AHMAD, A.; ALAM, S.: Integration of RSM with Grey based Taguchi Method for optimization of pulsed TIG welding process parameters. *Materials Today: Proceedings* 18 (2019), S. 5114–5127
- [ABP⁺18] APT, W.; BOVENSCHULTE, M.; PRIESACK, K.; WEISS, C.; HARTMANN, E. A.: Einsatz von digitalen Assistenzsystemen im Betrieb: Forschungsbericht 502 (2018)
- [ADC⁺16] ALLWOOD, J. M.; DUNCAN, S. R.; CAO, J.; GROCHE, P.; HIRT, G.; KINSEY, B.; KUBOKI, T.; LIEWALD, M.; STERZING, A.; TEKKAYA, A. E.: Closed-loop control of product properties in metal forming. *CIRP Annals* 65 (2016), Nr. 2, S. 573–596
- [AGJ10] AN, H.; GREEN, D. E.; JOHRENDT, J.: Multi-objective optimization and sensitivity analysis of tube hydroforming. *The International Journal of Advanced Manufacturing Technology* 50 (2010), Nr. 1-4, S. 67–84
- [AH15] AL-GHAMDI, K. A.; HUSSAIN, G.: Forming forces in incremental forming of a geometry with corner feature: Investigation into the effect of forming parameters using response surface approach. *The International Journal of Advanced Manufacturing Technology* 76 (2015), Nr. 9-12, S. 2185–2197
- [Alb09] ALBERS, S., Hrsg.: *Methodik der empirischen Forschung*. 3., überarb. und erw. Aufl. Wiesbaden: Gabler, 2009
- [And13] ANDREAS RAUSCHERT: Kognitives Assistenzsystem zur Führung unbemannter Luftfahrzeuge in bemannt-unbemannten Flugmissionen. Dissertation. München: Universität der Bundeswehr München, 2013.
- [AP18] ANGLANI, A.; PACELLA, M.: Logistic Regression and Response Surface Design for Statistical Modeling of Investment Casting Process in Metal Foam Production. *Procedia CIRP* 67 (2018), S. 504–509
- [Bam08] BAMBACH, M.: *Process strategies and modelling approaches for asymmetric incremental sheet forming*: Zugl.: Aachen, Techn. Hochsch., Diss., 2007. Bd. 139. Umformtechnische Schriften. Aachen: Shaker, 2008
- [Bay23] BAYERISCHES LANDESAMT FÜR UMWELT: So klingt materialeffiziente Zerspaltung: Unterstützung der internen Qualitätskontrolle durch Sensorik und KI. *Weniger ist Mehr - Gute Beispiele für Ressourceneffizienz* (2023).
- [BCK⁺07] BLUTNER, D.; CRAMER, S.; KRAUSE, S.; MÖNKES, T.; NAGEL, L.; REINHOLZ, A.; WITTHAUT, M.: „Assistenzsysteme für die Entscheidungsunterstützung“: Ergebnisbericht der Arbeitsgruppe 5. Sonderforschungsbereich 559. 2007

- [BDH⁺12] BORZYKH, M.; DAMEROW, U.; HENKE, C.; TRÄCHTLER, A.; HOMBERG, W.: Model-based Design of Self-Correcting Strategy for a Punch Bending Machine. *IFAC Proceedings Volumes* 45 (2012), Nr. 6, S. 1551–1555
- [BKTW14] BEATRICE, B. A.; KIRUBAKARAN, E.; THANGAIAH, P. R. J.; WINS, K. L. D.: Surface Roughness Prediction using Artificial Neural Network in Hard Turning of AISI H13 Steel with Minimal Cutting Fluid Application. *Procedia Engineering* 97 (2014), S. 205–211
- [BLFS16] BUSTILLO, A.; LÓPEZ DE LACALLE, L. N.; FERNÁNDEZ-VALDIVIELSO, A.; SANTOS, P.: Data-mining modeling for the prediction of wear on forming-taps in the threading of steel components. *Journal of Computational Design and Engineering* 3 (2016), Nr. 4, S. 337–348
- [Bög09] BÖGE, A.: *Handbuch Maschinenbau: Grundlagen und Anwendungen der Maschinenbau-Technik*. 19. Auflage. Wiesbaden: Vieweg+Teubner, 2009
- [BPMH07] BEHRENS, B.-A.; PÖSSE, O.; MILCH, M.; HELMS, G.: Optimization of ironing processes by means of DOE and FEA. *Production Engineering* 1 (2007), Nr. 1, S. 3–8
- [BRCG17] BRITO, M.; RAMOS, A. L.; CARNEIRO, P.; GONÇALVES, M. A.: Combining SMED methodology and ergonomics for reduction of setup in a turning production area. *Procedia Manufacturing* 13 (2017), S. 1112–1119
- [BU20] BOTSCH, M.; UTSCHICK, W.: *Fahrzeugsicherheit und automatisiertes Fahren: Methoden der Signalverarbeitung und des maschinellen Lernens*. Cincinnati: Hanser Publications, 2020
- [CSS18] CERNAVIN, O.; SCHRÖTER, W.; STOWASSER, S., Hrsg.: *Prävention 4.0: Analysen und Handlungsempfehlungen für eine produktive und gesunde Arbeit 4.0*. Wiesbaden: Springer, 2018.
- [DBP⁺18] DENKENA, B.; BERND-ARNO, B.; PETER, G.; JÖRG, K.; JENS P., W.: *WGP-Standpunkt Industriearbeitsplatz 2025*. Hannover, 2018
- [DD11] DANKERT, J.; DANKERT, H.: *Technische Mechanik: Statik, Festigkeitslehre, Kinematik/Kinetik*. 6. überarbeitete Auflage. Wiesbaden: Vieweg+Teubner Verlag, 2011.
- [DHK⁺16] DARWINABELE, N.; HOFFMANN, S.; KUHNEN, C.; LUDWIG, T.; SCHÄFER, W.; SCHWEITZER, M.; WULF, V.: Supporting the Set-up Processes by Cyber Elements based on the Example of Tube Bending. 2016
- [DIN03] DIN DEUTSCHES INSTITUT FÜR NORMUNG E.V.: *DIN 8580: Fertigungsverfahren: Begriffe, Einteilung*. Berlin, 2003
- [DK19] DWIVEDY, M.; KALLURI, V.: The effect of process parameters on forming forces in single point incremental forming. *Procedia Manufacturing* 29 (2019), S. 120–128
- [DLV⁺18] DÖBEL, I.; LEIS, M.; VOGELSANG, M. M.; NEUSTROEV, D.; PETZKA, H.; RIEMER, A.; RÜPING, S.; VOSS, A.; WEGELE, M.; WELZ, J.: *Maschinelles Lernen: Eine Analyse zu Kompetenzen, Forschung und Anwendungen* (2018)

- [DPB⁺16] DURO, J. A.; PADGET, J. A.; BOWEN, C. R.; KIM, H. A.; NASSEHI, A.: Multi-sensor data fusion framework for CNC machining monitoring. *Mechanical Systems and Signal Processing* 66-67 (2016), S. 505–520
- [DTB⁺14] DAMEROW, U.; TABAKAJEW, D.; BORZYKH, M.; SCHAERMANN, W.; HOMBERG, W.; TRÄCHTLER, A.: Concept for a Self-correcting Sheet Metal Bending Operation. *Procedia Technology* 15 (2014), S. 439–446
- [Ewe06] EWERS, R.: *Prozessauslegung und Optimierung des CNC-gesteuerten Form-drückens: Zugl.: Dortmund, Univ., Diss., 2005*. Dortmunder Umformtechnik. Aachen: Shaker, 2006
- [FG14] FU, Z.; GONG, P.: The study for stability of closed-loop control system based on multiple-step incremental air-bending forming of sheet metal. *The International Journal of Advanced Manufacturing Technology* 71 (2014), Nr. 1-4, S. 357–364
- [FKL⁺13] FÖLLINGER, O.; KONIGORSKI, U.; LOHMANN, B.; ROPPENECKER, G.; TRÄCHTLER, A.: *Regelungstechnik: Einführung in die Methoden und ihre Anwendung*. 11. Auflage. Berlin: VDE-Verlag, 2013
- [FSM⁺15] FUNK, M.; SHIRAZI, A. S.; MAYER, S.; LISCHKE, L.; SCHMIDT, A.: Pick from Here: An Interactive Mobile Cart Using In-Situ Projection for Order Picking. *ACM* (2015).
- [GBCG11] GISARIO, A.; BARLETTA, M.; CONTI, C.; GUARINO, S.: Springback control in sheet metal bending by laser-assisted bending: Experimental analysis, empirical and neural network modelling. *Optics and Lasers in Engineering* 49 (2011), Nr. 12, S. 1372–1383
- [GHKK18] GROCHE, P.; HOPPE, F.; KESSLER, T.; KLEEMANN, A.: Industrial Working Environment 2025. *New Developments in Sheet Metal Forming* (2018), S. 125–136
- [Gör92] GÖRGEL, U. B.: *Computer Integrated Manufacturing und Wettbewerbsstrategie*. Springer eBook Collection Business and Economics. Wiesbaden und s.l.: Gabler Verlag, 1992
- [GSH⁺18] GRÄLER, M.; SPRINGER, R.; HENKE, C.; TRÄCHTLER, A.; HOMBERG, W.: Assisted setup of forming processes: compensation of initial stochastic disturbances. *Procedia Manufacturing* 25 (2018), S. 358–364
- [GWHT19] GRÄLER, M.; WALLOW, A.; HENKE, C.; TRÄCHTLER, A.: Assisted setup of forming processes: architecture for the integration of non-adjustable disturbances. *Procedia CIRP* 81 (2019), S. 1348–1353
- [HLL09] HALL, D. L.; LLINAS, J.; LIGGINS, M. E., Hrsg.: *Handbook of multisensor data fusion: Theory and practice*. Second edition. The electrical engineering and applied signal processing series. Boca Raton, FL: CRC Press, 2009.
- [HWSI19] HUBER, S.; WIEMER, H.; SCHNEIDER, D.; IHLENFELDT, S.: DMME: Data mining methodology for engineering applications – a holistic extension to the CRISP-DM model. *Procedia CIRP* 79 (2019), S. 403–408

- [JJC⁺16] JAMALUDIN, Z.; JAMALUDIN, J.; CHIEW, T. H.; ABDULLAH, L.; RAFAN, N. A.; MAHAROF, M.: Sustainable Cutting Process for Milling Operation Using Disturbance Observer. *Procedia CIRP* 40 (2016), S. 486–491
- [Joh19] JOHNSON, S. G.: *The NLopt nonlinear-optimization package*. 2019.
- [JS10] JANAKIRAMAN, V.; SARAVANAN, R.: Concurrent optimization of machining process parameters and tolerance allocation. *The International Journal of Advanced Manufacturing Technology* 51 (2010), Nr. 1-4, S. 357–369
- [Kar19] KARANDIKAR, J.: Machine learning classification for tool life modeling using production shop-floor tool wear data. *Procedia Manufacturing* 34, 47th SME North American Manufacturing Research Conference (2019), S. 446–454
- [KAS⁺16] KHAMNEH, M. E.; ASKARI-PAYKANI, M.; SHAHVERDI, H.; HADAVI, S. M. M.; EMAMI, M.: Optimization of spring-back in creep age forming process of 7075 Al-Alclad alloy using D-optimal design of experiment method. *Measurement* 88 (2016), S. 278–286
- [KAS17] KHAIRUSSHIMA, M. N.; AQELLA, A. N.; SHARIFAH, I.: Optimization of Milling Carbon Fibre Reinforced Plastic Using RSM. *Procedia Engineering* 184 (2017), S. 518–528
- [KB16] KUSS, M.; BUCHMAYR, B.: Damage minimised ball spinning process design. *Journal of Materials Processing Technology* 234 (2016), S. 10–17
- [KBA⁺14] KLOCKE, F.; BLATTNER, M.; ADAMS, O.; BROCKMANN, M.; VESELOVAC, D.: Compensation of Disturbances on Force Signals for Five-axis Milling Processes. *Procedia CIRP* 14 (2014), S. 472–477
- [KHRG15] KURRA, S.; HIFZUR RAHMAN, N.; REGALLA, S. P.; GUPTA, A. K.: Modeling and optimization of surface roughness in single point incremental forming process. *Journal of Materials Research and Technology* 4 (2015), Nr. 3, S. 304–313
- [KJ15] KIM, Y.; JEON, E. S.: Establishment of regression model for estimating shape parameters for vacuum-sealed glass panel using design of experiments. *Vacuum* 121 (2015), S. 113–119
- [KJR⁺18] KÜHN, A.; JOPPEN, R.; REINHART, F.; RÖLTGEN, D.; ENZBERG, S. von; DUMITRESCU, R.: Analytics Canvas – A Framework for the Design and Specification of Data Analytics Projects. *Procedia CIRP* 70 (2018), S. 162–167
- [KK08] KIEFER, T.; KUGI, A.: Model-based control of front-end bending in hot rolling processes. *IFAC Proceedings Volumes* 41 (2008), Nr. 2, S. 1645–1650
- [KkKB14] KANNAN, T. D. B.; KANNAN, G. R.; KUMAR, B. S.; BASKAR, N.: Application of Artificial Neural Network Modeling for Machining Parameters Optimization in Drilling Operation. *Procedia Materials Science* 5 (2014), S. 2242–2249
- [KKM⁺17] KLOCKE, F.; KAMPS, S.; MATTFELD, P.; SHIROBOKOV, A.; STAUDER, J.; TRAUTH, D.: Assistenzsysteme in der Produktionstechnik. *Virtuelle Instrumente in der Praxis VIP* (2017), S. 265–287

- [KKT⁺18] KRITZINGER, W.; KARNER, M.; TRAAR, G.; HENJES, J.; SIHN, W.: Digital Twin in manufacturing: A categorical literature review and classification. *IFAC PapersOnLine* (2018), S. 1016–1022
- [Klo18] KLOCKE, F.: *Fertigungsverfahren I: Zerspanung mit geometrisch bestimmter Schneide*. 9. Auflage. VDI-Buch. Berlin: Springer, 2018
- [KS14] KLETTI, J.; SCHUMACHER, J.: *Die perfekte Produktion*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014
- [KS15] KANT, G.; SANGWAN, K. S.: Predictive Modelling and Optimization of Machining Parameters to Minimize Surface Roughness using Artificial Neural Network Coupled with Genetic Algorithm. *Procedia CIRP* 31 (2015), S. 453–458
- [KS18] KUMAR, S.; SINGH, B.: Prediction of tool chatter in turning using RSM and ANN. *Materials Today: Proceedings* 5 (2018), Nr. 11, S. 23806–23815
- [LHRM18] LUJAN-MORENO, G. A.; HOWARD, P. R.; ROJAS, O. G.; MONTGOMERY, D. C.: Design of experiments and response surface methodology to tune machine learning hyperparameters, with a random forest case-study. *Expert Systems with Applications* 109 (2018), S. 195–205
- [LKL⁺16] LU, H.; KEARNEY, M.; LI, Y.; LIU, S.; DANIEL, W. J. T.; MEEHAN, P. A.: Model predictive control of incremental sheet forming for geometric accuracy improvement. *The International Journal of Advanced Manufacturing Technology* 82 (2016), Nr. 9-12, S. 1781–1794
- [LM08] LAHA, D.; MANDAL, P., Hrsg.: *Handbook of computational intelligence in manufacturing and production management*. New York: Information Science Reference, 2008
- [LZB17] LONG, F.; ZEILER, P.; BERTSCHE, B.: Modelling the flexibility of production systems in Industry 4.0 for analysing their productivity and availability with high-level Petri nets. *IFAC PapersOnLine* (2017), Nr. 50-1, S. 5680–5687.
- [MGP⁺18] MARTINS, M.; GODINA, R.; PIMENTEL, C.; SILVA, F.; MATIAS, J. C.: A Practical Study of the Application of SMED to Electron-beam Machining in Automotive Industry. *Procedia Manufacturing* 17 (2018), S. 647–654
- [MMA16] MYERS, R. H.; MONTGOMERY, D. C.; ANDERSON-COOK, C. M.: *Response Surface Methodology: Process and Product Optimization Using Designed Experiments*. 4. Auflage. New Jersey: John Wiley & Sons, Inc, 2016
- [Mon13] MONTGOMERY, D. C.: *Design and analysis of experiments*. 8. Auflage. Hoboken: John Wiley & Sons, Inc, 2013
- [MPRC13] MAKRIS, S.; PINTZOS, G.; RENTZOS, L.; CHRYSSOLOURIS, G.: Assembly support using AR technology based on automatic sequence generation. *CIRP Annals* 62 (2013), Nr. 1, S. 9–12
- [Nad06] NADINE HENKENJOHANN: Eine adaptive sequentielle Prozedur zur effizienten Optimierung des CNC-gesteuerten Druckprozesses. Dissertation. Dortmund: Universität Dortmund, 2006

- [NE09] NISBET, R.; ELDER, J.: *Handbook of Statistical Analysis and Data Mining Applications*. San Diego, CA, USA: Elsevier Science & Technology Books, 2009
- [NRMM15] NAYEBI, M.; RUHE, G.; MOTA, R. C.; MUFTI, M.: Analytics for Software Project Management – Where are We and Where do We Go? *Analytics for Software Projekt Management*. IEEE, 2015, S. 18–21
- [NS18] NEB, A.; STRIEG, F.: Generation of AR-enhanced Assembly Instructions based on Assembly Features. *Procedia CIRP* 72 (2018), S. 1118–1123
- [PAB⁺16] PONTES, F. J.; AMORIM, G. F.; BALESTRASSI, P. P.; PAIVA, A. P.; FERREIRA, J. R.: Design of experiments and focused grid search for neural network parameter optimization. *Neurocomputing* 186 (2016), S. 22–34
- [PGH⁺16] PEITZ, S.; GRÄLER, M.; HENKE, C.; MOLO, M. H.-v.; DELLNITZ, M.; TRÄCHTLER, A.: Multiobjective Model Predictive Control of an Industrial Laundry. *Procedia Technology* 26 (2016), S. 483–490
- [PKK17] PRINZ, C.; KREIMEIER, D.; KUHLENKÖTTER, B.: Implementation of a Learning Environment for an Industrie 4.0 Assistance System to Improve the Overall Equipment Effectiveness. *Procedia Manufacturing* 9 (2017), S. 159–166
- [Pow94] POWELL, M. J. D.: A direct search optimization method that models the objective and constraint functions by linear interpolation. *Advances in Optimization and Numerical Analysis* (1994), S. 51–67
- [QSAT19] QADER, B. S.; SUPENI, E. E.; ARIFFIN, M.; TALIB, A. A.: RSM approach for modeling and optimization of designing parameters for inclined fins of solar air heater. *Renewable Energy* 136 (2019), S. 48–68
- [Rei14] REITZ, A.: *Lean TPM: In 12 Schritten zum schlanken Mangementsystem*. 3. Auflage. München: mi-Fachverlag, 2014.
- [Rie51] RIEGEL, F.: *Rechnen an spanabhebenden Werkzeugmaschinen*. 3. Aufl. Berlin, Heidelberg: Springer Berlin Heidelberg, 1951.
- [SBK14] SUNDAR, R.; BALAJI, A. N.; KUMAR, R. S.: A Review on Lean Manufacturing Implementation Techniques. *Procedia Engineering* 97 (2014), S. 1875–1885
- [SBS⁺19] SCHÜTZER, K.; BERTAZZI, J. D. A.; SALLATI, C.; ANDERL, R.; ZANCUL, E.: Contribution to the development of a Digital Twin based on product lifecycle to support the manufacturing process. *Procedia CIRP* 84 (2019), S. 82–87
- [Sch15] SCHENK, M., Hrsg.: *Produktion und Logistik mit Zukunft: Digital Engineering and Operation*. Berlin Heidelberg: Springer Vieweg, 2015
- [SEB⁺19] STECKEN, J.; EBEL, M.; BARTELT, M.; POEPELBUSS, J.; KUHLENKÖTTER, B.: Digital Shadow Platform as an Innovative Business Model. *Procedia CIRP* 83 (2019), S. 204–209
- [SFMW18] SAADALLAH, A.; FINKELDEY, F.; MORIK, K.; WIEDERKEHR, P.: Stability prediction in milling processes using a simulation-based Machine Learning approach. *Procedia CIRP* 72 (2018), S. 1493–1498

- [SGH⁺18] SPRINGER, R.; GRÄLER, M.; HOMBERG, W.; HENKE, C.; TRÄCHTLER, A.: Model-based setup assistant for progressive tools. *AIP Conference Proceedings* (2018)
- [SHPN18] STÜRMLINGER, T.; HAARB, C.; PANDTLEC, J.; NIEMEYERD, V.: Development of a wear model of a manufacturing system based on external smart production data on the example of a spring coiling machine. *Procedia Manufacturing* (2018), S. 232–236
- [SN19] SUBRAHMANYAM, M.; NANCHARAI, T.: Optimization of process parameters in wire-cut EDM of Inconel 625 using Taguchi's approach. *Materials Today: Proceedings* (2019)
- [SRH93] SHINGO, S.; RAAB, H. H.; HESSE, R., Hrsg.: *Das Erfolgsgeheimnis der Toyota-Produktion*. 2. Auflage. Japan-Service. Landsberg: Verlag Moderne Industrie, 1993
- [SSF⁺18] SOUSA, E.; SILVA, F.; FERREIRA, L. P.; PEREIRA, M. T.; GOUVEIA, R.; SILVA, R. P.: Applying SMED methodology in cork stoppers production. *Procedia Manufacturing* 17 (2018), S. 611–622
- [Sta20] STATISTISCHES BUNDESAMT: Bruttoinlandsprodukt für Deutschland 2019: Begleitmaterial zur Pressekonferenz am 15. Januar 2020 in Berlin (2020).
- [SVGd10] SÁNCHEZ LASHERAS, F.; VILÁN VILÁN, J. A.; GARCÍA NIETO, P. J.; DEL COZ DÍAZ, J. J.: The use of design of experiments to improve a neural network model in order to predict the thickness of the chromium layer in a hard chromium plating process. *Mathematical and Computer Modelling* 52 (2010), Nr. 7-8, S. 1169–1176
- [SvH10] SIEBERTZ, K.; VAN BEBBER, D.; HOCHKIRCHEN, T.: *Statistische Versuchsplanung: Design of Experiments (Doe)*. VDI-Buch. Dordrecht: Springer, 2010
- [Sys06] SYSKA, A., Hrsg.: *Produktionsmanagement*. Wiesbaden: Gabler, 2006
- [TEGP13] TORRES-TREVIÑO, L. M.; ESCAMILLA-SALAZAR, I. G.; GONZÁLEZ-ORTÍZ, B.; PRAGA-ALEJO, R.: An expert system for setting parameters in machining processes. *Expert Systems with Applications* 40 (2013), Nr. 17, S. 6877–6884
- [TNW⁺16] TANABE, S.; NAKAGAWA, H.; WATANABE, T.; MINAMI, H.; KANO, M.; URBANETZ, N. A.: Setting the process parameters for the coating process in order to assure tablet appearance based on multivariate analysis of prior data. *International journal of pharmaceutics* 511 (2016), Nr. 1, S. 341–350
- [Trä18] TRÄCHTLER, A., Hrsg.: *Ressourceneffiziente Selbstoptimierende Wäscherei: Ergebnisse des ReSerW-Projekts*. Intelligente Technische Systeme - Lösungen aus dem Spitzencluster it's OWL. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018.
- [Tre18] TREUDE, T.: *Rohre biegen mit Cyberbrille*. Siegen, 2018.
- [vHv15] VAN DEN BOOGAARD, T.; HAVINGA, J.; VAN TIJUM, R.: Model-based control of strip bending in mass production. *CIRP Annals* 64 (2015), Nr. 1, S. 297–300

- [Vin16] VINARICKY, E., Hrsg.: *Elektrische Kontakte, Werkstoffe und Anwendungen: Grundlagen, Technologien, Prüfverfahren*. 3. Aufl. 2016. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016
- [VMV⁺16] VASANTH, S.; MUTHURAMALINGAM, T.; VINOTHKUMAR, P.; GEETHAPRIYAN, T.; MURALI, G.: Performance Analysis of Process Parameters on Machining Titanium (Ti-6Al-4V) Alloy Using Abrasive Water Jet Machining Process. *Procedia CIRP* 46 (2016), S. 139–142
- [WD06] WESTKÄMPER, E.; DECKER, M.: *Einführung in die Organisation der Produktion*. Springer-Lehrbuch. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 2006.
- [WH18] WISCHMANN, S.; HARTMANN, E. A.: *Zukunft der Arbeit – Eine praxisnahe Betrachtung*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018
- [WK18] WEIDNER, R.; KARAFILLIDIS, A., Hrsg.: *Technische Unterstützungssysteme, die die Menschen wirklich wollen: Dritte transdisziplinäre Konferenz : Hamburg 2018*. Hamburg, Deutschland: Helmut-Schmidt-Universität, 2018

Anhang

Lösungen für das Integral

$$\Phi(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du.$$

Die Spalten geben die zweite Nachkommastelle für z an.

Tabelle A0-1: Kumulierte Standardnormalverteilung, nach [Mon13, S. 684]

-	0	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0	0.5	0.504	0.508	0.512	0.516	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.591	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.648	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.67	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.695	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.719	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.758	0.7611	0.7642	0.7673	0.7703	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.791	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.834	0.8365	0.8389
1	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.877	0.879	0.881	0.883
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.898	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.937	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.975	0.9756	0.9761	0.9767
2	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.983	0.9834	0.9838	0.9842	0.9846	0.985	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.989
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.992	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.994	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.996	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.997	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.998	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986

Versuchsplanung

Tabelle A0-2: Versuchsplan für die Voruntersuchung

Nummer	J1	J2	J3	J4	J5
1	-0.5	-0.5	-0.5	-0.5	0.5
2	-0.5	-0.5	-0.5	0.5	-0.5
3	-0.5	-0.5	0.5	-0.5	-0.5
4	-0.5	-0.5	0.5	0.5	0.5
5	-0.5	0.5	-0.5	-0.5	-0.5
6	-0.5	0.5	-0.5	0.5	0.5
7	-0.5	0.5	0.5	-0.5	0.5
8	-0.5	0.5	0.5	0.5	-0.5
9	0.5	-0.5	-0.5	-0.5	-0.5
10	0.5	-0.5	-0.5	0.5	0.5
11	0.5	-0.5	0.5	-0.5	0.5
12	0.5	-0.5	0.5	0.5	-0.5
13	0.5	0.5	-0.5	-0.5	0.5
14	0.5	0.5	-0.5	0.5	-0.5
15	0.5	0.5	0.5	-0.5	-0.5
16	0.5	0.5	0.5	0.5	0.5

Tabelle A0-3: Sortierter Versuchsplan für die Regressionsmodelle

Nummer	J1	J2	J3	J4	J5
1	-0.5	-0.5	-0.5	0	-0.5
2	-0.5	-0.5	-0.5	0	0.5
3	-0.5	-0.5	0.5	0	-0.5
4	-0.5	-0.5	0.5	0	0.5
5	-0.5	0.5	-0.5	0	-0.5
6	-0.5	0.5	-0.5	0	0.5
7	-0.5	0.5	0.5	0	-0.5
8	-0.5	0.5	0.5	0	0.5
9	0.5	-0.5	-0.5	0	-0.5
10	0.5	-0.5	-0.5	0	0.5
11	0.5	-0.5	0.5	0	-0.5
12	0.5	-0.5	0.5	0	0.5
13	0.5	0.5	-0.5	0	-0.5
14	0.5	0.5	-0.5	0	0.5
15	0.5	0.5	0.5	0	-0.5
16	0.5	0.5	0.5	0	0.5
17	-1	0	0	0	0
18	1	0	0	0	0
19	0	-1	0	0	0
20	0	1	0	0	0
21	0	0	-1	0	0
22	0	0	1	0	0
23	0	0	0	0	-1
24	0	0	0	0	1
25	0	0	0	0	0
26	0	0	0	0	0
27	0	0	0	0	0
28	0	0	0	0	0
29	0	0	0	0	0
30	-0.5	0	0	0	0
31	0.5	0	0	0	0
32	0	-0.5	0	0	0
33	0	0.5	0	0	0
34	0	0	-0.5	0	0
35	0	0	0.5	0	0
36	0	0	0	0	-0.5
37	0	0	0	0	0.5

Tabelle A0-4: Randomisierter Versuchsplan für die Regressionsmodelle

Nummer	J1	J2	J3	J4	J5
8	-0.5	0.5	0.5	0	0.5
17	-1	0	0	0	0
19	0	-1	0	0	0
26	0	0	0	0	0
34	0	0	-0.5	0	0
35	0	0	0.5	0	0
15	0.5	0.5	0.5	0	-0.5
28	0	0	0	0	0
25	0	0	0	0	0
12	0.5	-0.5	0.5	0	0.5
6	-0.5	0.5	-0.5	0	0.5
9	0.5	-0.5	-0.5	0	-0.5
18	1	0	0	0	0
30	-0.5	0	0	0	0
10	0.5	-0.5	-0.5	0	0.5
21	0	0	-1	0	0
33	0	0.5	0	0	0
37	0	0	0	0	0.5
31	0.5	0	0	0	0
36	0	0	0	0	-0.5
2	-0.5	-0.5	-0.5	0	0.5
16	0.5	0.5	0.5	0	0.5
27	0	0	0	0	0
5	-0.5	0.5	-0.5	0	-0.5
4	-0.5	-0.5	0.5	0	0.5
29	0	0	0	0	0
11	0.5	-0.5	0.5	0	-0.5
23	0	0	0	0	-1
13	0.5	0.5	-0.5	0	-0.5
24	0	0	0	0	1
32	0	-0.5	0	0	0
22	0	0	1	0	0
20	0	1	0	0	0
1	-0.5	-0.5	-0.5	0	-0.5
3	-0.5	-0.5	0.5	0	-0.5
7	-0.5	0.5	0.5	0	-0.5
14	0.5	0.5	-0.5	0	0.5

Erklärung zur Zitation von Inhalten aus studentischen Arbeiten

In Ergänzung zu meinem Antrag auf Zulassung zur Promotion in der Fakultät für Maschinenbau der Universität Paderborn erkläre ich gemäß §11 der Promotionsordnung und unter Beachtung der Regelung zur Zitation studentischer Arbeiten:

Die von mir vorgelegte Dissertation habe ich selbstständig verfasst, und ich habe keine anderen als die dort angegebenen Quellen und Hilfsmittel benutzt. Es sind keine Inhalte studentischen Ursprungs (studentische Arbeiten) in dieser Dissertation enthalten.

Ich habe die verwendeten Arbeiten entsprechend der Regelung „Zitation aus studentischen Arbeiten in Dissertationen“ zitiert.

**Heinz Nixdorf Institut –
Interdisziplinäres Forschungszentrum
für Informatik und Technik**

Das Heinz Nixdorf Institut ist ein Forschungszentrum der Universität Paderborn. Es entstand 1987 aus der Initiative und mit Förderung von Heinz Nixdorf. Damit wollte er Ingenieurwissenschaften und Informatik zusammenführen, um wesentliche Impulse für neue Produkte und Dienstleistungen zu erzeugen. Dies schließt auch die Wechselwirkungen mit dem gesellschaftlichen Umfeld ein.

Die Forschungsarbeit orientiert sich an dem Programm „Dynamik, Mobilität, Vernetzung: Eine neue Schule des Entwurfs der technischen Systeme von morgen“. In der Lehre engagiert sich das Heinz Nixdorf Institut in Studiengängen der Informatik, der Ingenieurwissenschaften und der Wirtschaftswissenschaften.

Heute wirken am Heinz Nixdorf Institut neun Professoren mit insgesamt 150 Mitarbeiterinnen und Mitarbeitern. Pro Jahr promovieren hier etwa 20 Nachwuchswissenschaftlerinnen und Nachwuchswissenschaftler.

**Heinz Nixdorf Institute –
Interdisciplinary Research Centre
for Computer Science and Technology**

The Heinz Nixdorf Institute is a research centre within the University of Paderborn. It was founded in 1987 initiated and supported by Heinz Nixdorf. By doing so he wanted to create a symbiosis of computer science and engineering in order to provide critical impetus for new products and services. This includes interactions with the social environment.

Our research is aligned with the program „Dynamics, Mobility, Integration: Enroute to the technical systems of tomorrow.“ In training and education the Heinz Nixdorf Institute is involved in many programs of study at the University of Paderborn. The superior goal in education and training is to communicate competencies that are critical in tomorrow's economy.

Today nine Professors and 150 researchers work at the Heinz Nixdorf Institute. Per year approximately 20 young researchers receive a doctorate.

Zuletzt erschienene Bände der Verlagsschriftenreihe des Heinz Nixdorf Instituts

- Bd. 392 PAI, A.: Computationally Efficient Modelling and Precision Position and Force Control of SMA Actuators. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 392, Paderborn, 2019 – ISBN 978-3-947647-11-8
- Bd. 393 ECHTERFELD, J.: Systematik zur Digitalisierung von Produktprogrammen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 393, Paderborn, 2020 – ISBN 978-3-947647-12-5
- Bd. 394 LOCHBICHLER, M.: Systematische Wahl einer Modellierungstiefe im Entwurfsprozess mechatronischer Systeme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 394, Paderborn, 2020 – ISBN 978-3-947647-13-2
- Bd. 395 LUKEI, M.: Systematik zur integrativen Entwicklung von mechatronischen Produkten und deren Prüfmittel. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 395, Paderborn, 2020 – ISBN 978-3-947647-14-9
- Bd. 396 KOHLSTEDT, A.: Modellbasierte Synthese einer hybriden Kraft-/Positionsregelung für einen Fahrzeugachsprüfstand mit hydraulischem Hexapod. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 396, Paderborn, 2021 – ISBN 978-3-947647-15-6
- Bd. 397 DREWEL, M.: Systematik zum Einstieg in die Plattformökonomie. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 397, Paderborn, 2021 – ISBN 978-3-947647-16-3
- Bd. 398 FRANK, M.: Systematik zur Planung des organisationalen Wandels zum Smart Service-Anbieter. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 398, Paderborn, 2021 – ISBN 978-3-947647-17-0
- Bd. 399 KOLDEWEY, C.: Systematik zur Entwicklung von Smart Service-Strategien im produzierenden Gewerbe. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 399, Paderborn, 2021 – ISBN 978-3-947647-18-7
- Bd. 400 GAUSEMEIER, J. (Hrsg.): Vorausschau und Technologieplanung. 16. Symposium für Vorausschau und Technologieplanung, Heinz Nixdorf Institut, 2. und 3. Dezember 2021, Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 400, Paderborn, 2021 – ISBN 978-3-947647-19-4
- Bd. 401 BRETZ, L.: Rahmenwerk zur Planung und Einführung von Systems Engineering und Model-Based Systems Engineering. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 401, Paderborn, 2021 – ISBN 978-3-947647-20-0
- Bd. 402 WU, L.: Ultrabreitbandige Sampler in SiGe-BiCMOS-Technologie für Analog-Digital-Wandler mit zeitversetzter Abtastung. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 402, Paderborn, 2021 – ISBN 978-3-947647-21-7
- Bd. 403 HILLEBRAND, M.: Entwicklungssystematik zur Integration von Eigenschaften der Selbstheilung in Intelligente Technische Systeme. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 403, Paderborn, 2021 – ISBN 978-3-947647-22-4
- Bd. 404 OLMA, S.: Systemtheorie von Hardware-in-the-Loop-Simulationen mit Anwendung auf einem Fahrzeugachsprüfstand mit parallelkinematischem Lastsimulator. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 404, Paderborn, 2022 – ISBN 978-3-947647-23-1

Zuletzt erschienene Bände der Verlagsschriftenreihe des Heinz Nixdorf Instituts

- Bd. 405 FECHTELPETER, C.: Rahmenwerk zur Gestaltung des Technologietransfers in mittelständisch geprägten Innovationsclustern. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 405, Paderborn, 2022 – ISBN 978-3-947647-24-8
- Bd. 406 OLEFF, C.: Proaktives Management von Anforderungsänderungen in der Entwicklung komplexer technischer Systeme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 406, Paderborn, 2022 – ISBN 978-3-947647-25-5
- Bd. 407 JAVED, A. R.: Mixed-Signal Baseband Circuit Design for High Data Rate Wireless Communication in Bulk CMOS and SiGe BiCMOS Technologies. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 407, Paderborn, 2022 – ISBN 978-3-947647-26-2
- Bd. 408 DUMITRESCU, R., KOLDEWEY, C.: Daten-gestützte Projektplanung. Fachbuch. Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 408, Paderborn, 2022 – ISBN 978-3-947647-27-9
- Bd. 409 PÖHLER, A.: Automatisierte dezentrale Produktionssteuerung für cyber-physische Produktionssysteme mit digitaler Repräsentation der Beschäftigten. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 409, Paderborn, 2022 – ISBN 978-3-947647-28-6
- Bd. 410 RÜDDENKLAU, N.: Hardware-in-the-Loop-Simulation von HD-Scheinwerfer-Steuergeräten zur Entwicklung von Lichtfunktionen in virtuellen Nachtfahrten. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 410, Paderborn, 2023 – ISBN 978-3-947647-29-3
- Bd. 411 BIEMELT, P.: Entwurf und Analyse modell-prädiktiver Regelungsansätze zur Steigerung des Immersionsempfindens in inter-aktiven Fahrsimulationen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 411, Paderborn, 2023 – ISBN 978-3-947647-30-9
- Bd. 412 HAAKE, C.-J., MEYER AUF DER HEIDE, F., PLATZNER, M., WACHSMUTH, H., WEHRHEIM, H. (Eds.): On-The-Fly Computing - Individualized IT-Services in dynamic markets, Collaborative Research Centre 901 (2011 - 2023), Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 412, Paderborn, 2023 – ISBN 978-3-947647-31-6
- Bd. 413 DUMITRESCU, R.; HÖLZLE, K. (Hrsg.): Vorausschau und Technologieplanung. 17. Symposium für Vorausschau und Technologieplanung, Heinz Nixdorf Institut, 14./15. September 2023, Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 413, Paderborn, 2023 – ISBN 978-3-947647-32-3
- Bd. 414 ABUGHANNAM, S.: Low-power Direct-detection Wake-up Receiver at 2.44 GHz for Wireless Sensor Networks. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 414, Paderborn, 2024 – ISBN 978-3-947647-33-0
- Bd. 415 REINHOLD, J.: Systematik zur muster-basierten Transformation von Wertschöpfungssystemen für Smart Services. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 415, Paderborn, 2024 – ISBN 978-3-947647-34-7
- Bd. 416 YANG, X.: Eine Methode zur Unterstüt-zung von Entscheidungen bei der Ent-wicklung modularer Leichtbauprodukte. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 416, Paderborn, 2024 – ISBN 978-3-947647-35-4



Ein Trend in der Produktion sind individualisierte Produkte und damit eine höhere Variantenvielfalt, die idealerweise durch effiziente Produktionsprozesse hergestellt werden. Effizienz bedeutet in diesem Fall, dass die Produkte kostengünstig und bedarfsgerecht hergestellt werden. Der Trend geht hierbei auch in der Massenproduktion zu einer flexiblen Produktion, um das gebundene Kapital zu reduzieren und zeitnah auf Kundenwünsche reagieren zu können. Dies führt zu einem häufigeren Umrüsten der Werkzeuge in den Maschinen und somit zu einem immer häufigeren Einrichten der Prozesse. In dieser Arbeit wird eine Systematik für ein adaptives Einrichtassistenzsystem entwickelt, welches den Maschinenbediener beim Einrichten mithilfe eines definierten Vorgehens durch den Prozess leitet. Der Bediener wird dabei unterstützt die momentane Produktqualität zu bewerten und bekommt einen quantitativen Vorschlag zur Variation der Justagemöglichkeiten. So kann der Einrichtprozess zielgerichteter und fehlerfreier durchgeführt werden.