

1 Einleitung

Introduction

Die wirtschaftliche Nutzung von Daten ist immer öfter der Grund für Wettbewerbsvorteile in diversen Wirtschaftszweigen.¹ Insbesondere im industriellen Produktionsumfeld – wie bspw. der Elektromobilproduktion – besitzen datenbasierte Ansätze hohes Potenzial, die Effizienz bestehender sowie auch künftiger Produktionen aus ökonomischer sowie ökologischer Sicht zu steigern und damit die unternehmerische Wettbewerbsfähigkeit langfristig zu sichern.² In diesem Kontext wird bspw. cyber-physischen Systemen (CPS) – ein systemischer Verbund aus Produktions- und Informationstechnik mit dem Ziel der autonom organisierenden Automatisierung von Fertigungsprozessen zur Erhöhung der Prozessstabilität – eine enorme Bedeutung zugemessen.³ Eine häufig auftretende Problematik beim Einsatz von CPS besteht in fehlenden oder unzureichenden Datengrundlagen, um das zugrundeliegende Modell für seinen spezifischen Anwendungsfall zu trainieren.⁴ Da die für das Training erforderlichen Datenmenge im Laufe der Produktion immer weiter zunimmt, besteht diese datenseitige Diskrepanz insbesondere zu Beginn von Produktionsanläufen neuartiger Produkte. Zeitgleich lässt sich aus kürzer werdenden Entwicklungszyklen sowie einer steigenden Variantenvielfalt⁵ eine steigende Anzahl solcher Produktionsanläufe ableiten, deren zentrales Charakteristikum in der Instabilität der Produktion und hohen Ausschussraten besteht⁶. Die frühzeitige Entwicklung, Integration und Nutzung datenbasierter Ansätze als Gegenmaßnahmen birgt für die Zukunft folglich ein enorm hohes Potenzial zur Wertschöpfungssteigerung in Anlaufphasen solch neuartiger Produkte. Die vorliegende Dissertation greift dieses Potenzial auf und stellt eine anwendungsorientierte Methodik zur frühzeitigen Integration datenbasierter Ansätze in die Anlaufphase disruptiver Produkte zur Verfügung.

In dem folgenden Kapitel wird dafür zunächst die der Dissertation zugrundeliegende Ausgangssituation erläutert (Kapitel 1.1) sowie die sich daraus ergebende Problemstellung beschrieben (Kapitel 1.2). Im Anschluss daran wird die produktions- und datenwissenschaftliche Zielsetzung der Dissertation festgelegt (Kapitel 1.3), woraufhin diese wissenschaftstheoretisch eingeordnet wird (Kapitel 1.4). Im darauffolgenden Kapitel werden die Hauptforschungsfrage sowie die Nebenforschungsfragen definiert (Kapitel 1.5), die im weiteren Verlauf der vorliegenden Arbeit beantwortet werden sollen. Abschließend wird die übergeordnete Struktur der Arbeit dargestellt und in die Phasen der zugrundeliegenden Forschungsmethodik eingeordnet (Kapitel 1.6).

¹ vgl. Grimm, Schnitzer et al. 2021 – Transformation gestalten, S. 8.

² vgl. Fuchs 2022 – Künstliche Intelligenz in der Produktion.

³ vgl. Bachmann, Bradke et al. 2015 – Forschungs- und Technologieperspektiven 2030, S. 173f.

⁴ vgl. Döbel, Leis et al. 2018a – Maschinelles Lernen, S. 61.

⁵ vgl. Schuh, Riesener et al. 2020 – Industrie 4.0, S. 485.

⁶ vgl. Lanza 2005 – Simulationsbasierte Anlaufunterstützung, S. 8ff.

1.1 Ausgangssituation

Die Automobilindustrie befindet sich derzeit im Umbruch. Die zunehmende Verschärfung der Emissionsgrenzwerte von Seiten der Politik^{7,8} zwingt produzierende Unternehmen der Automobilbranche zu einer zunehmenden Elektrifizierung ihrer Fahrzeugflotte.⁹ Das wachsende Umweltbewusstsein auf Seiten der Bevölkerung¹⁰ und die daraus resultierende erhöhte Nachfrage nach Elektrofahrzeugen¹¹ verstärkt diesen Wandel zusätzlich. Dies spiegelt sich auch in aktuellen Prognosen der weltweiten Pkw-Neuzulassungen für die kommenden Jahre wider (siehe Abbildung 1-1).




Abbildung 1-1: Prognostizierter Pkw-Absatz weltweit nach Antriebsart bis 2040^{12,13}

Der mit dieser Prognose einhergehende sukzessive Übergang vom Verbrennungsmotor zum Elektromotor hat neben den Auswirkungen auf Produktebene ebenso folgenschwere Konsequenzen auf Produktionsebene. Der grundlegend verschiedene Aufbau von Elektromotoren gegenüber Verbrennungsmotoren resultiert in einer nahezu vollständigen Substitution der für die Produktion erforderlichen Maschinen- und Anlagentechnik¹⁴. Solch tiefgreifende Veränderungen machen jahrzehntelang gesammelte Erfahrungswerte in der Produktion größtenteils obsolet.¹⁵

⁷ vgl. Umweltbundesamt 2021 – Emissionsstandards.

⁸ vgl. BMU 2020 – CO₂-Flottengrenzwerte, S. 2ff.

⁹ vgl. Kampker, Vallée et al. 2018 – Elektromobilität, S. 27f.

¹⁰ vgl. Umweltbundesamt 2022 – Umweltbewusstsein und Umweltverhalten.

¹¹ vgl. BMWK 2022 – Elektromobilität in Deutschland.

¹² vgl. Harrison 2021 – Electric Vehicle Analysis, S. 14.

¹³ i.A.a. Heimes, Kampker et al. 2023 – Elektromobilität als Schlüsseltechnologie, S. 44.

¹⁴ vgl. Abele, Hohenstein et al. 2009 – Wandel im PKW-Antriebsstrang, S. 3.

¹⁵ vgl. Heimes, Kampker et al. 2023 – Aktuelle Herausforderungen der Elektromobilität, S. 35.

Hinzu kommt, dass sich im Bereich des elektrischen Antriebsstrangs seit Beginn des beschriebenen Umbruchs bis dato noch keine dominante Technologie am Markt etabliert hat. Aus den in den letzten Jahrzehnten immer kürzer werdenden Innovations- und Entwicklungszyklen¹⁶ sowie der steigenden Variantenvielfalt auf Produktseite^{17,18} lassen sich weitere Produktwechsel und damit einhergehende Veränderungen der erforderlichen Produktionstechnik¹⁹ in den kommenden Jahren ableiten. Für die Produktion hat dies zur Folge, dass in Zukunft mehr disruptive Produkte in immer kürzer werdenden Abständen hergestellt werden müssen, wodurch zwangsläufig auch die Anzahl an Produktionsanläufen steigen wird²⁰. Aus Produktionssicht kommt der Anlaufphase als Übergangsphase zwischen der Produkt- bzw. Prozessentwicklung und der Serienproduktion daher eine steigende Bedeutung zu.

Zeitgleich zu den genannten Entwicklungen ist im produzierenden Gewerbe seit einigen Jahren ein weiterer Trend zu beobachten. Neben der fortschreitenden Elektrifizierung gewinnt auch die Digitalisierung der Produktion unter dem Begriff der vierten Industriellen Revolution immer mehr an Bedeutung.²¹ Analog zum Trend zur Elektrifizierung besitzt auch die Digitalisierung ebenso viele Chancen wie Herausforderungen für die produzierende Industrie. Im Zuge der Digitalisierung wird sich in den kommenden Jahren vor allem der Bereich der Künstlichen Intelligenz (KI) weiter etablieren^{22,23}. Im Produktionsumfeld hat sich bereits in den vergangenen Jahren das Maschinelle Lernen (ML) als Teilbereich der KI als vielversprechender Ansatz gezeigt^{24,25}. Die Methoden des ML werden dabei häufig zur Optimierung von Produktionsprozessen auf Basis adaptiver Fertigungsprozesse^{26,27} eingesetzt, die die Fähigkeiten des Menschen hinsichtlich Schnelligkeit und Vielschichtigkeit insbesondere bei steigender Komplexität des Anwendungsfalls weit übertreffen. Folglich bergen die Digitalisierung der Produktion und die zugrundeliegenden Methoden ein hohes Potenzial, um den oben genannten Herausforderungen zu begegnen, vor denen produzierende Unternehmen der Automobilindustrie derzeit und in den kommenden Jahren stehen. Für die Nutzbarmachung dieser Methoden in Form von datenbasierten Ansätzen müssen jedoch bestimmte Voraussetzungen erfüllt sein sowie gewisse Problemstellungen angegangen werden²⁸, auf die im folgenden Kapitel näher eingegangen wird.

¹⁶ vgl. Schuh, Riesener et al. 2020 – Industrie 4.0, S. 485.

¹⁷ vgl. Tietjen, Decker 2020 – FMEA-Praxis, S. 1f.

¹⁸ vgl. Schuh, Schmidt 2014 – Produktionsmanagement, S. V.

¹⁹ vgl. Heimes, Kampker et al. 2023 – Aktuelle Herausforderungen der Elektromobilität, S. 35.

²⁰ vgl. Schuh, Stölzle et al. 2008 – Anlaufmanagement, S. 1.

²¹ vgl. Obermaier 2019 – Industrie 4.0 und digitale Transformation, S. V.

²² vgl. Seifert, Bürger et al. 2018 – Potenziale der künstlichen Intelligenz, S. 5.

²³ vgl. Demary, Goeke 2019 – Künstliche Intelligenz, S. 16.

²⁴ vgl. Quack 2020 – Wie Maschinelles Lernen die Produktion verändert.

²⁵ vgl. Deloitte 2020 – State of AI in the Enterprise, S. 8.

²⁶ vgl. Baum 2018 – Industrie 4.0, S. 5.

²⁷ vgl. Günzel 2020 – Smarte Fabrik.

²⁸ vgl. Döbel, Leis et al. 2018b – Maschinelles Lernen, S. 32ff.

1.2 Problemstellung

Die Grundvoraussetzung für den Einsatz datenbasierter Ansätze aus dem Bereich des Maschinellen Lernens ist das Vorhandensein einer ausreichenden Datengrundlage für den erforderlichen Lernprozess^{29,30}. Im Verlauf einer Serienproduktion wird diese Datengrundlage mit jeder produzierten Einheit größer, da mit der Zeit immer mehr Datensätze³¹ generiert werden und damit als Datengrundlage zur Verfügung stehen (vgl. Abbildung 1-2).

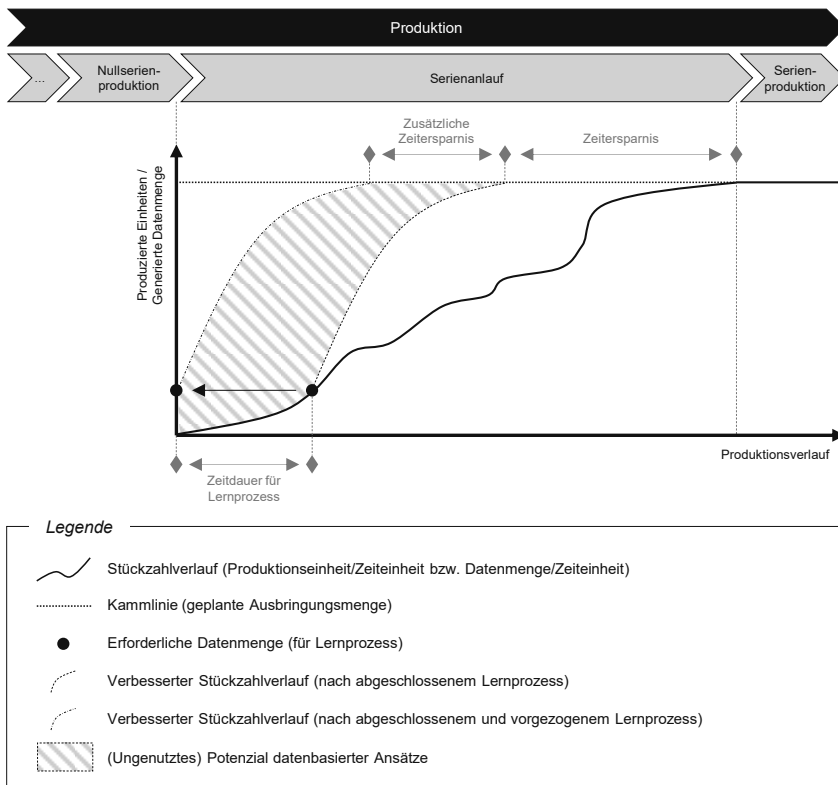


Abbildung 1-2: Stückzahlverlauf und Datengenerierung (schematisch)^{32,33,34}

²⁹ vgl. Matzka 2021 – Künstliche Intelligenz in den Ingenieurwissenschaften, S. 9.

³⁰ vgl. Schuh, Riesener et al. 2020 – Industrie 4.0, S. 475.

³¹ Anmerkung: Die Datensätze werden bspw. durch in die Produktionsumgebung integrierte Sensor- und Messtechnik generiert.

³² i.A.a. Corsten, Gössinger et al. (Hg.) 2018 – Produktions- und Logistikmanagement, S. 540.

³³ i.A.a. Dombrowski, Hanke 2017 – Lean Ramp-up, S. 387.

³⁴ i.A.a. Burggräf, Schuh 2021 – Fabrikplanung, S. 505.

Dies gilt sowohl bis zur Erreichung der maximal geplanten Ausbringungsmenge je Zeiteinheit (Kammlinie) als auch während der nachfolgenden Serienproduktion.³⁵ Zu Beginn von Anlaufphasen steht folglich keine Datengrundlage zur Verfügung, um datenbasierte Ansätze für ihren Einsatz in der Produktion ausreichend anzulernen. Daraus folgt, dass zunächst eine bestimmte Menge an Einheiten produziert werden muss, um die – je nach Komplexität des Anwendungsfalls – erforderliche Datenmenge zu generieren (vgl. Abbildung 1-2). Insbesondere in Anlaufphasen neuartiger Produkte (wie bspw. im Bereich der Elektromobilproduktion) treten jedoch häufig unerwartete Probleme auf, die eine erhöhte Ausschussrate und eine geringe Gesamtanlageneffektivität (engl.: Overall Equipment Effectiveness, OEE) nach sich ziehen.^{36,37} Die Ursachen solcher Wertschöpfungsverluste liegen dabei häufig in prozessseitigen Wechselwirkungen verketteter Anlagen³⁸ oder schwankenden Eingangsbedingungen, auf die produzierende Unternehmen häufig keinen Einfluss haben. Derartige Fehler können zwar durch präventive Maßnahmen frühzeitig identifiziert werden³⁹, die Entwicklung geeigneter, echtzeitfähiger Gegenmaßnahmen für alle potenziell auftretenden Fehler ist jedoch insbesondere in frühen Phasen der Produkt- und Prozessentwicklung nicht realistisch. Daraus ergibt sich die folgende produktionswissenschaftliche Problemstellung der vorliegenden Arbeit:

**Die produktionswissenschaftliche Problemstellung besteht in
Wertschöpfungsverlusten in Anlaufphasen disruptiver Produkte
in Form von Zeit- und Kostenineffizienzen,
die auf die Nichtexistenz geeigneter Gegenmaßnahmen
für qualitätsbeeinflussende Fehlermöglichkeiten zurückzuführen sind.**

Für die oben genannten Herausforderungen stellen datenbasierte Ansätze wie bspw. adaptive Prozesssteuerungen, die häufig auf Methoden des Maschinellen Lernens basieren und in Form von CPS in die Produktionsumgebung implementiert werden, ein effektives Werkzeug dar^{40,41,42}. Der Effekt des Einsatzes solcher Ansätze spiegelt sich insbesondere in einer geringeren Ausschussrate und einer entsprechend höheren Ausbringungsmenge je Zeiteinheit wider. Dieser auftretende Effekt, der folglich zu einem früheren Erreichen der Kammlinie (Time-to-Volume) und daher zu einer verkürzten Anlaufphase führt, zeigt sich konsequenterweise jedoch erst nach abgeschlossenem Lernprozess des datenbasierten Ansatzes (siehe Strichlinie in Abbildung 1-2).

³⁵ Anmerkung zu Abbildung 1-2: Das Integral unter dem Stückzahlverlauf (in der Einheit Produktionseinheit/Zeiteinheit) über der Zeit ergibt die bis zu einem bestimmten Zeitpunkt in der Anlaufphase insgesamt produzierten Produktionseinheiten.

³⁶ vgl. Heimes, Kampker et al. 2023 – Vom Prototypen zur Serienfertigung, S. 220.

³⁷ vgl. Wildemann 2004 – Präventive Handlungsstrategien für den Produktionsanlauf, S. 17f.

³⁸ vgl. Fleischer, Schopp et al. 2006 – Diagnosestrategien für einen schnellen Ramp-up, S. 509.

³⁹ vgl. Tietjen, Decker 2020 – FMEA-Praxis, S. 7.

⁴⁰ vgl. Schmitt, Ellerich et al. 2020 – Datenbasiertes Qualitätsmanagement, S. 505ff.

⁴¹ vgl. Wennker 2020 – Künstliche Intelligenz in der Praxis, S. 138f.

⁴² vgl. Hatiboglu, Schuler et al. 2019 – Einsatzfelder von Künstlicher Intelligenz, S. 22.

Wird nun angenommen, dass der Lernprozess bereits vor der Anlaufphase stattgefunden hat, ergibt sich ein weiterhin verbesserter Stückzahlverlauf (siehe Strichpunktlinie in Abbildung 1-2) und eine damit einhergehende zusätzliche Zeitersparnis bis zur Erreichung der Kammlinie. Die schraffierte Fläche zeigt damit das bisher ungenutzte Potenzial, das datenbasierte Ansätze in Anlaufphasen disruptiver Produkte⁴³ besitzen.⁴⁴ Um dieses Potenzial in vollem Umfang nutzen zu können, muss die erforderliche Datenmenge jedoch bereits zu Beginn der Anlaufphase in ausreichender Qualität sowie Quantität vorliegen⁴⁵. Es wird somit geschlussfolgert, dass zu Beginn von Anlaufphasen disruptiver Produkte vor dem Hintergrund des Einsatzes datenbasierter Ansätze eine Diskrepanz zwischen erforderlicher und existierender Datenbasis besteht (vgl. Abbildung 1-3).

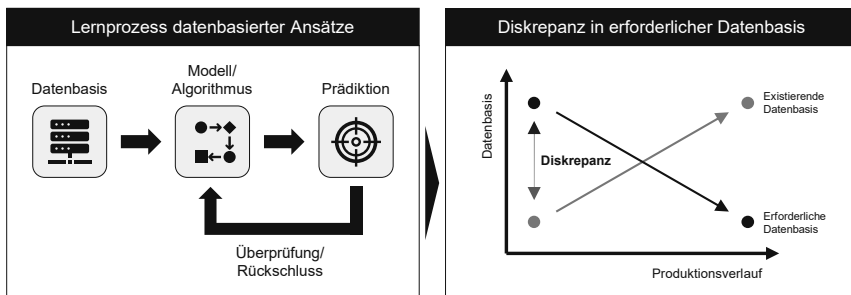


Abbildung 1-3: Datenseitige Diskrepanz in Produktionsanläufen (schematisch)

Daraus ergibt sich unmittelbar die datenwissenschaftliche Problemstellung der vorliegenden Arbeit:

**Die datenwissenschaftliche Problemstellung besteht in der
Diskrepanz zwischen erforderlicher und existierender Datenbasis
vor dem Hintergrund des frühzeitigen Einsatzes datenbasierter Ansätze
als Gegenmaßnahme für qualitätsbeeinflussende Fehlermöglichkeiten.**

Aus dieser Problemstellung ergibt sich die Herausforderung, die bestehende Diskrepanz durch geeignete Lösungsansätze zu schließen, was zur Zielsetzung der vorliegenden Arbeit führt.

⁴³ Ein Produkt gilt als disruptiv, wenn sich dieses aufgrund einer technologischen Innovation von seinem Vorgängerprodukt deutlich unterscheidet (vgl. Christensen, von den Eichen et al. 2012 – The Innovator's Dilemma, S. 51ff. sowie Kampker, Kreisköther et al. 2017 – Anlauf disruptiver Produkte, S. 58.)

⁴⁴ Erläuterung zu Abbildung 1-2: Die Integralfäche zwischen den beiden Stückzahlverläufen (in der Einheit Produktionseinheit/Zeiteinheit) ergibt die Anzahl an zusätzlichen Produktionseinheiten, die durch bereits vorab angelernte datenbasierte Ansätze produziert werden.

⁴⁵ vgl. Döbel, Leis et al. 2018b – Maschinelles Lernen, S. 11.