

Automatisierte Fabrikplanung durch datenbasierte Generierung von Fabrikplanungsergebnissen

Herausforderungen bei der Data-Science-Anwendung

M. Riesener, E. Schukat, S. Wang, A. Obladen

ZUSAMMENFASSUNG Die effiziente Planung von Fabriken gewinnt in einem immer dynamischeren Wettbewerbsumfeld an entscheidender Bedeutung. Die automatisierte Generierung von Planungsinformationen aus Produktionsdaten bietet eine Möglichkeit, Fehler in der Fabrikplanung zu vermeiden, den Fabrikplanungsprozess zu beschleunigen und die Effizienz der Fabrikplanung somit zu steigern. Die Herausforderungen bei der Umsetzung solcher Ansätze werden nachfolgend untersucht und geeignete Lösungsmaßnahmen abgeleitet.

STICHWÖRTER

Fabrikplanung, Digitalisierung, Datentechnik

Challenges in the application of data science

ABSTRACT Efficient factory planning is becoming increasingly important in an ever more dynamic competitive environment. The automated generation of planning information from production data provides an approach to avoid errors in factory planning, accelerate the factory planning process and thus increase the efficiency of factory planning. The challenges involved in implementing such approaches are analyzed below and suitable solutions are derived.

1 Motivation

Die fortschreitende Entwicklung industrieller Technologien, Anforderungen an nachhaltige Fabriken und sich wandelnde politische Rahmenbedingungen führen zu einer signifikanten Komplexitätssteigerung in der Fabrikplanung [1]. Traditionelle Ansätze entsprechen diesen Anforderungen nicht mehr und resultieren daher in zunehmend ineffizienten Fabrikplanungsprozessen [2]. Diese Veränderungen erfordern von produzierenden Unternehmen somit nicht nur eine Anpassung, sondern eine grundlegende Transformation ihrer Fabrikplanungsmethoden [1]. In diesem Kontext erweist sich die Anwendung von Data-Science-Methoden als vielversprechender Ansatz, um den wachsenden Anforderungen an die Fabrikplanung zu begegnen und ihre Effizienz zu steigern.

Data-Science ermöglicht eine umfassende Analyse großer und heterogener Datensätze aus verschiedenen Bereichen [3]. Durch fortgeschrittene Analysetechniken lassen sich so fundierte Erkenntnisse aus Daten bestehender Produktionssysteme gewinnen, um neue Fabriken zu planen. Die Integration von Data-Science in die Fabrikplanung ermöglicht dabei nicht nur eine erhöhte Effizienz durch eine Verkürzung der Planungszeiträume, sondern auch eine Reduktion der Planungskosten sowie eine Steigerung der Ergebnisqualität. Der Einsatz von Data-Science in der Fabrikplanung stellt somit einen erfolgversprechenden Weg dar, um der steigenden Komplexität industrieller Anforderungen zu begegnen.

2 State of the Art

Die aktuelle Forschungslage im Bereich Fabrikplanung und Data-Science zeigt eine Vielzahl von Ansätzen und Entwicklungen, die als Ausgangspunkt für die Weiterentwicklung dieser Themen dienen können. Die nachfolgende State-of-the-Art-Analyse bietet einen umfassenden Überblick über relevante Ansätze, um den aktuellen Stand des Wissens zu illustrieren und potenzielle Forschungslücken aufzuzeigen.

2.1 Fabrikplanung

Die Fabrikplanung beschreibt den Prozess der Gestaltung und Organisation von Produktionssystemen. Sie umfasst die Planung, Gestaltung und Optimierung von Produktionsanlagen, um optimale Effizienz, Produktqualität und Wirtschaftlichkeit zu gewährleisten [4]. Ziel ist es, den Produktionsprozess reibungslos zu gestalten und Ressourcen optimal zu nutzen. Zwei grundlegende Ansätze in der Fabrikplanung sind die Greenfield- und Brownfield-Planung. Greenfield-Planung bezieht sich auf die Planung und Errichtung neuer Produktionsanlagen ohne einschränkende Restriktionen wie bestehende Fabrikgebäude. Die Brownfield-Planung beschreibt die Umgestaltung oder Erweiterung bestehender Anlagen, deren spezifische Eigenschaften im Rahmen der Fabrikplanung berücksichtigt werden müssen [1]. Aufgrund des überwiegenden Anteils der Brownfield Projekte gegenüber Greenfield-Projekten in Deutschland wird sich im weiteren Verlauf dieses Beitrags primär auf die Brownfield-Planung fokussiert [5].

Die zunehmende Komplexität in der Fabrikplanung stellt eine bedeutende Herausforderung dar, die nicht nur technologische Fortschritte und die Dynamik volatiler Märkte, sondern auch die enge Verknüpfung der diversen Planungsaufgaben innerhalb der Fabrikplanung widerspiegelt. [6] In der Praxis führen diese Herausforderungen dabei häufig zu einer Verlängerung der erforderlichen Planungszeiträume und darüber hinaus zu erhöhten Planungskosten, da bestehende Ansätze der Fabrikplanung den entsprechenden Anforderungen nicht gerecht werden [7]. Die effiziente Bewältigung dieser Komplexität ist daher von entscheidender Bedeutung für die Wettbewerbsfähigkeit von produzierenden Unternehmen [2].

2.1.1 Fabrikplanungsvorgehen

Phasenbasierte Fabrikplanungsvorgehen bieten einen strukturierten Ansatz, um der Komplexität in modernen Fabrikplanungsprojekten gerecht zu werden. Sie unterteilen den Planungsprozess in diskrete, inhaltlich sowie methodisch abgrenzbare und systematisch strukturierte Planungsphasen, wobei jede Phase spezifische, zunehmend detailliertere Planungsaufgaben der Fabrikplanung enthält [4]. Zu den etablierten phasenbasierten Fabrikplanungsvorgehen zählen die Ansätze nach *Aggteleky* [8], *Wiendahl et al.* [9], dem Verein Deutscher Ingenieure [10] und *Grundig* [4]. Die lineare Verkettung der erforderlichen Planungsaufgaben vernachlässigt jedoch dynamische Einflüsse auf die Fabrikplanung, da Veränderungen an Planungsvorgaben in fortgeschrittenen Planungsphasen nicht oder nur unter erheblichem Mehraufwand im Fabrikplanungsergebnis berücksichtigt werden können [1].

Iterative und agile Fabrikplanungsvorgehen stellen eine effektive Reaktion auf diese Einschränkungen dar. Im Gegensatz zu phasenbasierten Ansätzen erlauben sie eine kontinuierliche Anpassung und Überarbeitung von Planungsaufgaben während des gesamten Planungsprozesses. Durch wiederholte Iterationen der einzelnen Planungsaufgaben können Veränderungen in den Planungsvorgaben jederzeit für das weitere Vorgehen berücksichtigt werden [6]. Dies ermöglicht eine erhöhte Flexibilität, verbesserte Anpassungsfähigkeit und die Möglichkeit, auf unvorhergesehene Entwicklungen effizient zu reagieren. Darüber hinaus bietet die iterative Herangehensweise agiler Fabrikplanungsaufgaben die Möglichkeit, Planungsaufgaben zu parallelisieren [1, 11]. Durch die partielle Weiterentwicklung der einzelnen Planungsaufgaben kann der Reifegrad der jeweiligen Planungsergebnisse inkrementell gesteigert und die erforderliche Planungszeit gleichzeitig reduziert werden. Ein Beispiel für einen solchen Ansatz stellt das Aachener Fabrikplanungsvorgehen dar [11–13].

2.1.2 Aachener Fabrikplanungsvorgehen

Das Aachener Fabrikplanungsvorgehen stellt ein agiles und iteratives Planungsvorgehen dar, das entsprechend den projektindividuellen Rahmenbedingungen und Restriktionen konfiguriert werden kann [14]. Das Vorgehen kapselt dabei Planungsaufgaben mit einem hohen Grad an gegenseitigen Abhängigkeiten in Planungsmodulen. Für alle Planungsmodule sind dabei die zur Erfüllung der integrierten Planungsaufgaben erforderlichen Eingangsinformationen sowie die generierten Ausgangsinformationen definiert. Der iterative und agile Ansatz des Aachener Fabrikpla-

nungsvorgehens wird dabei durch die Verknüpfung der Planungsmodulen durch die Planungsinformationen erreicht, indem Ausgangsinformationen eines Planungsmoduls als Eingangsinformationen eines anderen Planungsmoduls fungieren. Das so entstehende Netzwerk aus Planungsmodulen und Planungsinformationen bildet die sogenannte Modullandkarte, aus der relevante Planungsaufgaben projektindividuell abgeleitet werden können [12]. Durch die Selektion von ausschließlich projektrelevanten Planungsaufgaben aus der Modullandkarte kann der insgesamt erforderliche Aufwand der Fabrikplanung durch das Aachener Fabrikplanungsvorgehen reduziert, die Planungszeit reduziert und die Planungseffizienz somit gesteigert werden [6].

2.2 Data-Science

Data-Science stellt eine interdisziplinäre Forschungs- und Anwendungsdomäne dar, die Methoden aus Statistik, Informatik und maschinellem Lernen vereint, um automatisiert Erkenntnisse aus großen Datenmengen zu gewinnen. Dies erlaubt die Extraktion von Informationen, die von Unternehmen als fundierte Entscheidungsunterstützung genutzt werden kann. Durch Datenanalyse, Modellierung und maschinelle Auswertung trägt die Data-Science dabei zur Optimierung von Prozessen sowie zum Vorhersagen von Entwicklungen und zur Lösung komplexer Probleme bei.

Einen strukturierenden Rahmen für die Extraktion von Wissen aus großen Datenmengen kann dabei die Knowledge Discovery in Databases (KDD) bieten, die den Prozess von der Vorbereitung, über die Datenpräparation und -transformation bis zur Nutzung der generierten Informationen umfasst. Die KDD wird dabei in neun Schritte unterteilt. Im ersten Schritt wird ein Verständnis für die angestrebte Methode der Data-Science entwickelt und die Ziele der Untersuchung definiert. Anschließend wird im zweiten Schritt aus Teilmengen bestehender Datensätze ein Zieldatensatz erstellt, der als Grundlage für die weitere Untersuchung dient. Bevor mit der Extraktion von Informationen begonnen werden kann, muss jedoch zunächst im dritten Schritt eine Bereinigung und Vorbereitung des Zieldatensatzes vorgenommen werden. Dabei werden bekannte Datenkontaminationen und Rauschen aus dem Zieldatensatz entfernt, um die Ergebnisqualität nicht zu beeinträchtigen. Im vierten Schritt werden die bereinigten Daten reduziert, indem repräsentative Datenmerkmale identifiziert und invariante Daten eliminiert werden. Anschließend wird im fünften Schritt eine auf die Ziele der Data-Science Anwendung ausgerichtete Data-Mining-Methode ausgewählt. Die erforderlichen Anwendungsparameter der Data-Mining Methode werden im sechsten Schritt ausgewählt, bevor im siebten Schritt die Data-Mining-Methode angewendet wird und relevante Muster im Zieldatensatz gesucht werden. Diese werden im achten Schritt interpretiert. Wenn anhand der dabei generierten Erkenntnisse noch keine abschließende Aussage über das Ziel der Untersuchung getroffen werden kann, werden ergänzend Vorgaben für eine Iteration der KDD festgelegt. Abschließend werden im neunten Schritt der KDD die generierten Erkenntnisse dokumentiert und angewendet. Die Integration der KDD in die Data-Science bildet somit die Grundlage einer effizienten Identifikation von datenbasierten Zusammenhängen und der strukturierten Generierung von Informationen aus komplexen Datensätzen. [15]

2.2.1 Data-Engineering

Nachdem in Kapitel 2.2 die allgemeinen Grundlagen der Data-Science vorgestellt wurden, wird im folgenden Abschnitt auf die datentechnischen Grundlagen der Data-Science eingegangen. Dazu werden die Begriffe Data-Engineering und Big-Data definiert sowie die im Fabrikplanungskontext relevanten Datenquellen eingeführt. Das Ziel von Data-Engineering liegt im Verständnis, der Selektion sowie der Aufbereitung der zugrunde liegenden Daten. Der Prozess ist der Datenanalyse vorgelagert und befasst sich mit der Beschaffung und Zusammenführung der Daten aus unterschiedlichen Unternehmensbereichen und Datenarchitekturen. [3]

Grundlage des Data-Engineering bilden häufig Big-Data-Datensätze. Bei ihnen handelt es sich um Datensätze, die sich durch spezielle Kriterien auszeichnen, die sie wertvoll für Anwendungen der Data-Science macht. So werden Big-Data-Datensätze durch die fünf Kriterien Volume, Variety, Velocity, Veracity und Value charakterisiert. Es handelt sich somit um Datensätze, die große Mengen an unterschiedlichen Informationen aus diversen Informationsquellen umfassen, die schnell abgerufen und verarbeitet werden können, ein hohes Maß an Informationsvalidität aufweisen und nutzbringend ausgewertet werden können. Durch die Kombination dieser Eigenschaften eignen sich Big-Data-Systeme besonders gut für die Identifikation von Mustern zur Ableitung von Erkenntnissen und Generieren von Informationen durch Data-Science-Methoden. [3]

Damit Computersysteme effizient arbeiten können, müssen diese durch eine geeignete Datenarchitektur unterstützt werden. Geeignete Datenarchitekturen müssen dabei zuverlässig, skalierbar und handhabbar aufgebaut werden. Zuverlässige Systeme zeichnen sich dabei durch eine Kombination aus robusten Hardwarekomponenten, fehlertoleranten Algorithmen und eine kontinuierliche Überwachung der eigenen Funktionstüchtigkeit aus, sodass eine hohe Verfügbarkeit sichergestellt werden kann. Die Skalierbarkeit eines Systems bezeichnet seine Fähigkeit, sich zukünftigen Veränderungen in den zu verarbeitenden Datenmengen anzupassen. Die Handhabbarkeit eines Systems beschreibt den Aufwand, der im Falle steigender Komplexität für seine Instandhaltung und Weiterentwicklung aufgewendet werden muss. Datenarchitekturen, die diese drei Anforderungen erfüllen, eignen sich für den Einsatz in der Data-Science. [16]

Der Prozess der Extraktion und Überführung von Daten aus einer oder mehreren Datenquellen in ein Zielsystem wird durch die drei Schritte Extrahieren, Transformieren, Laden (ETL) beschrieben. Dazu werden Daten aus gegebenen Datenquellen entnommen, entsprechend der Vorgaben des jeweiligen Handlungsfalls verarbeitet und anschließend an die anfragende Stelle weitergeleitet [16]. Im Fabrikplanungs- und Produktionskontext lassen sich fünf Hauptquellen für Daten identifizieren. Die erste Quelle umfasst Management-Daten, die aus bestehenden IT-Systemen im Unternehmen stammen, darunter Systeme wie Enterprise Resource Planning, Manufacturing Execution System, Customer Relationship Management, Supply Chain Management und Product Data Management. Diese Daten beziehen sich auf verschiedene Aspekte wie Produktplanung, Auftragsfreigabe, Materialmanagement, Produktionsplanung und Inventarmanagement. Die zweite Quelle bezieht sich auf Daten von Maschinen und Anlagen, die Daten über Echtzeitleistung, Betriebsbedingungen und Prozessfolgen in Form von Eventlogs liefern. Die dritte

Datenquelle umfasst öffentlich zugängliche Daten zu geistigem Eigentum wie Patentschriften, zu öffentlicher Infrastruktur wie der Anbindung an das Straßen- und Schienennetz, zu Rahmenbedingungen im Fabrikplanungskontext wie zulässigen Bebauungsflächen sowie zu ökologischen Vorgaben für das Bauen und Betreiben von Fabriken. Die vierte Datenquelle umfasst Nutzungsdaten des Produkts, zu denen beispielsweise Betriebsbedingungen und Nutzungskontext zählen. Die fünfte Quelle enthält personenbezogene Daten wie Arbeitszeiterfassungen oder Prozessqualitätskennzahlen in Kombination mit Qualifikationsprofilen von Mitarbeitenden, aus denen Erkenntnisse für die Fabrikplanung gewonnen werden können. Ausgehend von diesen Datenquellen können mithilfe des ETL-Prozesses Daten strukturiert ausgewertet und für die Fabrikplanung bereitgestellt werden. [17]

2.2.2 Methoden der Data-Science

Nachdem im vorangehenden Kapitel die datentechnischen Grundlagen der Data-Science im Fabrikplanungskontext beleuchtet wurden, werden nachfolgend Methoden der Data-Science vorgestellt, die für den Anwendungsfall Fabrikplanung von Relevanz sind. Dazu werden zunächst Methoden zur Auswertung von Datensätzen vorgestellt. Anschließend wird auf Methoden zur Datenverarbeitung und -extraktion eingegangen.

Künstliche Intelligenz bezeichnet einen Bereich der Informatik, der sich mit der Entwicklung von Algorithmen und Systemen befasst, die es Computern ermöglichen, menschenähnliche Intelligenz, einschließlich Lernen, Problemlösung und Entscheidungsfindung, zu simulieren [18]. Im Kontext der Fabrikplanung bieten solche Ansätze die Möglichkeit, komplexe Muster in Datensätzen zu finden und somit Erkenntnisse zu generieren, die mithilfe manueller Auswertungsansätze nicht oder nur schwer identifizierbar wären.

Maschinelles Lernen bezeichnet ein Bereich der künstlichen Intelligenz, der Algorithmen und statistische Modelle verwendet, um Computern die Fähigkeit zu geben, aus Daten zu lernen und dadurch zunehmend genauere Ergebnisse zu generieren [19]. In der Fabrikplanung bietet maschinelles Lernen die Möglichkeit, komplexe Produktionsdaten zu analysieren und prädiktive Modelle zu entwickeln.

Deep Learning ist eine fortgeschrittene Form des maschinellen Lernens, bei der künstliche neuronale Netzwerke verwendet werden, um komplexe Muster und Hierarchien in Daten zu erfassen. [3] In der Fabrikplanung kann Deep Learning die Analyse komplexer Datenmengen ermöglichen, etwa in Bezug auf Produktionsabläufe oder Ressourcenmanagement. [20]

Data-Mining ist ein Prozess der Extraktion von bisher unbekannten, potenziell relevanten Informationen aus großen Datenmengen durch die Anwendung von statistischen und maschinellen Lernmethoden [3]. In der Fabrikplanung kann Data-Mining dazu verwendet werden, versteckte Muster und Zusammenhänge in Produktionsdaten zu entdecken. Durch die Analyse historischer Daten kann Data-Mining dazu beitragen, Engpässe zu identifizieren, Effizienzsteigerungen vorzuschlagen und fundierte Entscheidungen in Bezug auf Produktionsprozesse, Ressourcenallokation und Optimierungen zu ermöglichen. [21]

Natural Language Processing ist ein Bereich, der sich mit der Verarbeitung und Interpretation natürlicher menschlicher Sprache befasst [3]. Dies umfasst die Fähigkeit, Texte zu verstehen, zu generieren, zu übersetzen und auf Anfragen in menschenähnli-

cher Sprache zu reagieren. In der Fabrikplanung kann Natural Language Processing dazu verwendet werden, komplexe schriftliche Dokumente wie Berichte und Dokumentationen zu analysieren. [16]

Die vorgestellten Forschungsstände zu den Themen Fabrikplanung sowie Data-Science werden nachfolgend aufgegriffen und in den Kontext einer Effizienzsteigerung in der Fabrikplanung durch Anwendung von Data-Science Ansätzen gesetzt. Dazu wird zunächst die Notwendigkeit einer solchen Lösung motiviert. Anschließend wird auf die mit einer solchen Lösung verbundenen Herausforderungen eingegangen. Es werden Ansätze vorgestellt, wie diesen Herausforderungen begegnet werden kann. Für Herausforderungen, für die bisher keine Lösungen etabliert sind, werden Hypothesen zu möglichen Ansätzen beschrieben und als Forschungsausblick vorgestellt.

3 Herausforderungen datenbasierter Planungsinformationsgenerierung

Die zunehmende Komplexität von Fabrikplanungsprozessen stellt eine signifikante Herausforderung dar, die eine grundlegende Überarbeitung etablierter Planungsmethoden erfordert. Klassische phasenbasierte Ansätze, die historisch zur Fabrikplanung genutzt wurden, offenbaren ihre Ineffizienz angesichts der heutigen dynamischen und hochkomplexen Anforderungen an die Fabrikplanung. Diese herkömmlichen Methoden sind oft zu starr und unflexibel, um effizient auf sich verändernde Anforderungen, Technologien und Marktdynamiken zu reagieren. Zusätzlich geraten auch agile Planungsmethoden, die einst als Antwort auf dynamische Planungsanforderungen entwickelt wurden, aufgrund begrenzter Anwendbarkeit für hochkomplexe Planungsaufgaben, große Planungsteams und sicherheitskritische Planungsaufgaben zunehmend an ihre Grenzen, wenn es um die Bewältigung moderner Fabrikplanungsprozesse geht. [22]

Vor diesem Hintergrund wird die Notwendigkeit ersichtlich, agile Fabrikplanungsmethoden so weiterzuentwickeln, dass die Effizienz der Fabrikplanung weiter gesteigert wird, ohne dabei ihre Eigenschaft einzuschränken, auf dynamische Veränderungen der Planungsanforderungen zu reagieren. Im nachfolgenden Abschnitt wird auf die zu bewältigenden Herausforderungen eingegangen, um eine solche Lösung erfolgreich umzusetzen. Dazu werden zunächst bestehende Ansätze der Digitalisierung der Fabrikplanung untersucht. Anschließend wird eine Lösungshypothese zur Effizienzsteigerung agiler Fabrikplanungsmethoden durch den Einsatz von Data-Science Ansätze aufgestellt. Abschließend werden die Herausforderungen dargestellt, die für die Entwicklung einer solchen Lösung bewältigt werden müssen. Diese werden in themenfeldspezifische Herausforderungen im Kontext agiler Fabrikplanung (Kontextperspektive) und technische Herausforderungen der Data-Science (Datenperspektive) unterteilt.

In der modernen Fabrikplanung lassen sich bereits eine Vielzahl an digitalen Unterstützungsprogrammen finden, die den Fabrikplanungsprozess effektiver gestalten [23]. Diese Ansätze nutzen Technologien wie 3D-Modellierung, Visualisierung der Fabrik oder Dokumentationsstandards wie Building Information Modeling (BIM), um eine durchgängige Informationstransparenz während des gesamten Fabrikprozesses zu ermöglichen. Ebenso existieren bereits Ansätze der generativen Layoutplanung, die mithilfe von Algorithmen Fabriklayouts entwickeln können. Die Praxis zeigt jedoch, dass Ansätze zur generativen Layoutplanung

trotz ihres innovativen Ansatzes oft nur einzelne Aspekte der Layoutplanung berücksichtigen und daher lediglich begrenzte Anwendung finden [24]. Eine zentrale Erkenntnis besteht somit darin, dass sich die Anwendungsfälle sämtlicher etablierter Methoden zum Einsatz digitaler Technologien in der Fabrikplanung lediglich auf der Validierung bereits entwickelter Ergebnisse und der transparenten Darstellung bereits existierender Informationen beschränken. Es fehlen jedoch bisher praxistaugliche digitale Ansätze zur Herleitung und Entwicklung von Fabrikplanungsergebnissen. Die Herleitung solcher Ergebnisse erfolgt bislang nach wie vor manuell und unter dem subjektiven Einfluss des Erfahrungswissens der Fabrikplanenden. Diese manuelle Vorgehensweise führt selbst in agilen Planungsmethoden zu ineffizienten Fabrikplanungsprozessen. Dies resultiert in verlängerten Planungszeiten, dadurch erhöhten Planungskosten und zusätzlich zu einer reduzierten Ergebnisqualität aufgrund der subjektiven Beeinflussung durch die Fabrikplanenden.

Die zentrale Hypothese dieses Artikels besteht darin, dass durch den Einsatz von Data-Science-Methoden zur automatisierten Ableitung von Fabrikplanungsergebnissen die Einschränkungen etablierter Fabrikplanungsmethoden überwunden werden können. Der Einsatz von Data-Science erlaubt es dabei, große Datenmengen effizient zu analysieren, relevante Datenmuster zu identifizieren und wertschöpfende Aussagen für die Fabrikplanung abzuleiten. Eine Lösung, die Daten aus bestehenden Produktionssystemen untersucht, um daraus Erkenntnisse für neue Fabrikplanungsprojekte zu generieren, birgt dabei das Potenzial weite Teile wiederkehrender Standardtätigkeiten zu automatisieren. Dies ermöglicht eine deutliche Reduktion der erforderlichen manuellen Planungstätigkeiten und reduziert somit die zur Fabrikplanung erforderlichen Zeiträume sowie die verursachten Planungskosten, sodass die Effizienz der Fabrikplanung erheblich gesteigert werden kann.

Die Herausforderungen, die für die Entwicklung einer solchen Lösung zur automatisierten Herleitung von Fabrikplanungsergebnissen bewältigt werden müssen, werden nachfolgend vorgestellt. Dazu werden sowohl kontextbezogene Herausforderungen aus dem Bereich der Fabrikplanung untersucht, wie auch auf Herausforderungen im Bereich der Data-Science eingegangen (vgl. Bild 1).

3.1 Kontextperspektive

Herausforderung 1

Eine Herausforderung bei der automatisierten Herleitung von Fabrikplanungsergebnissen liegt in der Notwendigkeit, das komplexe Wissen und die Zusammenhänge, die bei der Entwicklung von Fabrikplanungsergebnissen eine Rolle spielen, systematisch zu strukturieren. Dies erfordert eine präzise Formalisierung von Fachwissen, das bisher oft auf individuellen Erfahrungen und intuitiven Prozessen beruht [1, 5]. Eine Automatisierung setzt voraus, dass dieses implizite Wissen in explizite Regeln übersetzt wird, die von digitalen Systemen verstanden und angewendet werden können [25].

Herausforderung 2

Eine weitere Herausforderung für die automatisierte Generierung von Fabrikplanungsergebnissen besteht in der inhärenten




Bild 1. Herausforderungen bei der Anwendung von Data Science zur automatisierten Generierung von Fabrikplanungsergebnissen.
Grafik: WZL der RWTH Aachen

Begrenztheit regelbasierter Systeme. Selbst unter der Annahme, die komplexen Sachbeziehungen und Interkorrelationen in Fabrikplanungsprojekten objektiv abbilden zu können, zeichnen sich Fabrikplanungsprojekte durch einen hohen Grad an Individualität der Planungsdetails aus [4]. Aufgrund dieser theoretisch unendlichen Komplexität von Fabrikplanungsprojekten stellt eine vollständige Automatisierung der Fabrikplanung keine wirtschaftlich tragfähige Lösung dar. Vielmehr nimmt der Mehrwert einer automatisierten Generierung von Fabrikplanungsinformationen mit steigender Anforderung an den Reifegrad des Ergebnisses zunehmend ab. Dies ist darauf zurückzuführen, dass sich mit zunehmender Anzahl an zu berücksichtigenden Variablen und folglich mit steigender Komplexität des regelbasierten Systems die Anzahl an Fehlern im Ergebnis exponentiell ansteigt [26]. Gleichzeitig verhält sich der Planungsaufwand derselben Berechnungen bei manuellem Vorgehen linear zur zugrunde liegenden Komplexität des regelbasierten Systems [27]. Diese Erkenntnisse deuten darauf hin, dass es einen wirtschaftlichen Grenzwert für die Komplexität eines regelbasierten Systems gibt, ab dem der Aufwand für die Entwicklung automatisierter Lösungen im Vergleich zur manuellen Entwicklung signifikant ansteigt. Dementsprechend bietet eine automatisierte Lösung insbesondere zu Beginn eines Fabrikplanungsprojekts einen deutlich größeren Mehrwert gegenüber der manuellen Entwicklung derselben Fabrikplanungsergebnisse (vgl. **Bild 2**).

Das Ziel für die Entwicklung eines solchen Ansatzes muss daher eine Lösung sein, die weite Teile der fabrikplanerischen Tätigkeit abdeckt, jedoch gleichzeitig ab dem Punkt des wirtschaftlichen Äquilibriums zwischen automatisierter und manueller Ergebnisentwicklung Zwischenlösungen ausgeben und die Finalisierung der Fabrikplanung menschlichen Fabrikplanenden übergeben kann [1].

3.2 Datenperspektive

Nachdem im vorangehenden Kapitel die Herausforderungen bei der Entwicklung einer Lösung zur automatisierten Generierung von Fabrikplanungsergebnissen aus der Kontextperspektive untersucht wurden, wird nachfolgend auf die Herausforderungen aus Datenperspektive eingegangen.

Herausforderung 3

Die Herausforderung der Daten- und Ergebniskonsistenz bei der Anwendung von Data-Science im Kontext der Fabrikplanung stellt ein zentrales Anliegen dar, das die Qualität und Zuverlässig-

keit von Analysen und Entscheidungsfindungen beeinflusst. In einem Umfeld, in dem Daten aus verschiedenen Quellen und Formaten stammen können, besteht die Schwierigkeit darin, eine einheitliche Datenbasis zu schaffen, um verlässliche Analyseergebnisse zu gewährleisten [28]. Datenkonsistenz beschreibt dabei die Notwendigkeit sicherzustellen, dass die gesammelten Daten frei von Widersprüchen und Redundanzen sind, um präzise und verlässliche Analysen zu ermöglichen. Parallel dazu stellt die Ergebniskonsistenz insbesondere für Systeme mehrerer verknüpfter Data-Science-Anwendungen einen entscheidenden Faktor dar, da unterschiedliche Analysemethoden oder Modelle zu verschiedenen Ergebnissen führen können. Die Gewährleistung der Konsistenz zwischen verschiedenen Analyseergebnissen und Modellen ist essenziell, um Vertrauen in die Entscheidungsfindung zu schaffen. [29]

Herausforderung 4

Neben der Daten- und Ergebniskonsistenz stellt auch die Datenverfügbarkeit eine zentrale Herausforderung für den Erfolg von Data-Science-Methoden dar. Dabei ist es entscheidend, dass Daten nicht nur in ausreichender Menge, sondern auch in geeigneter Qualität und rechtzeitig verfügbar sind. Fehlende oder verzögerte Daten können die Analyseprozesse beeinträchtigen und zu unvollständigen oder veralteten und somit irrelevanten Ergebnissen führen.

Herausforderung 5

Eine weitere Herausforderung für den effektiven Einsatz von Data-Science-Methoden stellen Datentransfers und die Integrati-

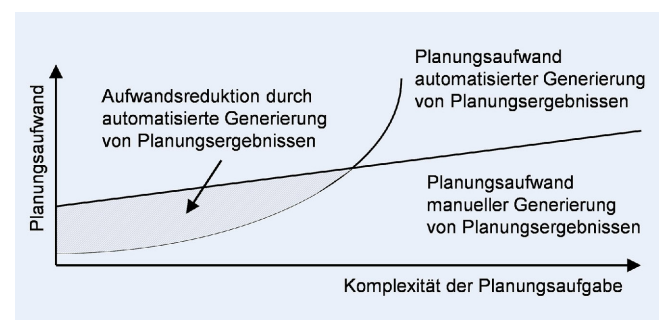


Bild 2. Reifegradabhängiger Planungsaufwand manueller und automatisierter Fabrikplanungsansätze. Grafik: WZL der RWTH Aachen

on von Daten in Datenverarbeitungssysteme dar. Angesichts der bereits thematisierten Vielfalt von Datenquellen und -formaten müssen Daten über verschiedene Plattformen und Systeme hinweg nahtlos transferiert und integriert werden können. Dies erfordert nicht nur die Bewältigung von technischer Heterogenität, sondern auch die Sicherstellung der Datenqualität und -konsistenz während der Übertragungsprozesse. [30]

Herausforderung 6

Nicht zuletzt manifestiert sich auch das Thema Datenschutz als zentrale Herausforderung der Data-Science angesichts der rasanten Zunahme von Datengenerierung, -verarbeitung und -analyse. Der Schutz sensibler Informationen sowie personenbezogener Daten erfordert nicht nur technologische Sicherheitsmaßnahmen, sondern auch die Implementierung effektiver rechtlicher und ethischer Rahmenbedingungen. Die Anonymisierung von Daten, das Einrichten robuster Zugriffskontrollen sowie transparente Datenschutzerklärungen sind entscheidende Aspekte, um sowohl unternehmerische Datenhoheit als auch die Privatsphäre hinsichtlich personenbezogener Daten zu wahren. [28]

4 Lösungsansätze für die automatisierte Generierung von Fabrikplanungsergebnissen

Im vorangehenden Kapitel wurden eine Reihe an Herausforderungen aufgezeigt, die für die Entwicklung einer Lösung zur automatisierten Generierung von Fabrikplanungsergebnissen bewältigt werden müssen. Nachfolgend werden diese Herausforderungen aufgegriffen und Ansätze vorgestellt, wie diesen begegnet werden kann. Dazu werden jeder Herausforderung konkrete Ansätze gegenübergestellt, die für die Anwendung von Data-Science-Ansätzen zur automatisierten Generierung von Fabrikpla-

nungsergebnissen erforderlich sind. Ein Überblick über diese Ansätze wird in Bild 3 gegeben.

Lösungsansatz 1

Die erste vorgestellte Herausforderung an die Entwicklung einer automatisierten Generierung von Fabrikplanungsergebnissen besteht in der Notwendigkeit, das komplexe Fachwissen der Fabrikplanung zu systematisieren. Ein bestehender Ansatz, um dieser Anforderung zu entsprechen, findet sich eingebettet in der agilen Fabrikplanungsmethode des Aachener Fabrikplanungsvorgehens. Grundlage des Aachener Fabrikplanungsvorgehens ist die Systematisierung der einzelnen Fabrikplanungsaufgaben in Module, die wiederum durch eindeutig definierte Fabrikplanungsinformationen miteinander verknüpft sind (vgl. Kapitel 2.1.2) [6]. Dieses praxiserprobte Gerüst an Planungsinformationen bildet somit eine optimale Grundlage für die weitere Entwicklung einer Lösung zur automatisierten Generierung von Fabrikplanungsergebnissen.

Lösungsansatz 2

Eine weitere Herausforderung an das Ergebnis besteht in der wertschöpfungsoptimierten Trennung automatisierter und manueller Fabrikplanungstätigkeiten. Auch hier bietet das Aachener Fabrikplanungsvorgehen durch sein reifegradbasiertes Planungsvorgehen eine geeignete Grundlage [11]. Um dieser Herausforderung zu begegnen sind zwei Schritte erforderlich. In einem ersten Schritt müssen diejenigen Planungsinformationen identifiziert werden, die sich basierend auf ihrem Inhalt und der für die Planung erforderlichen Informationen grundsätzlich für eine datenbasierte Herleitung eignen. Anschließend müssen im Rahmen der Entwicklung der automatisierten Generierung von Fabrikplanungsergebnissen für alle aufgegriffenen Planungsinformationen

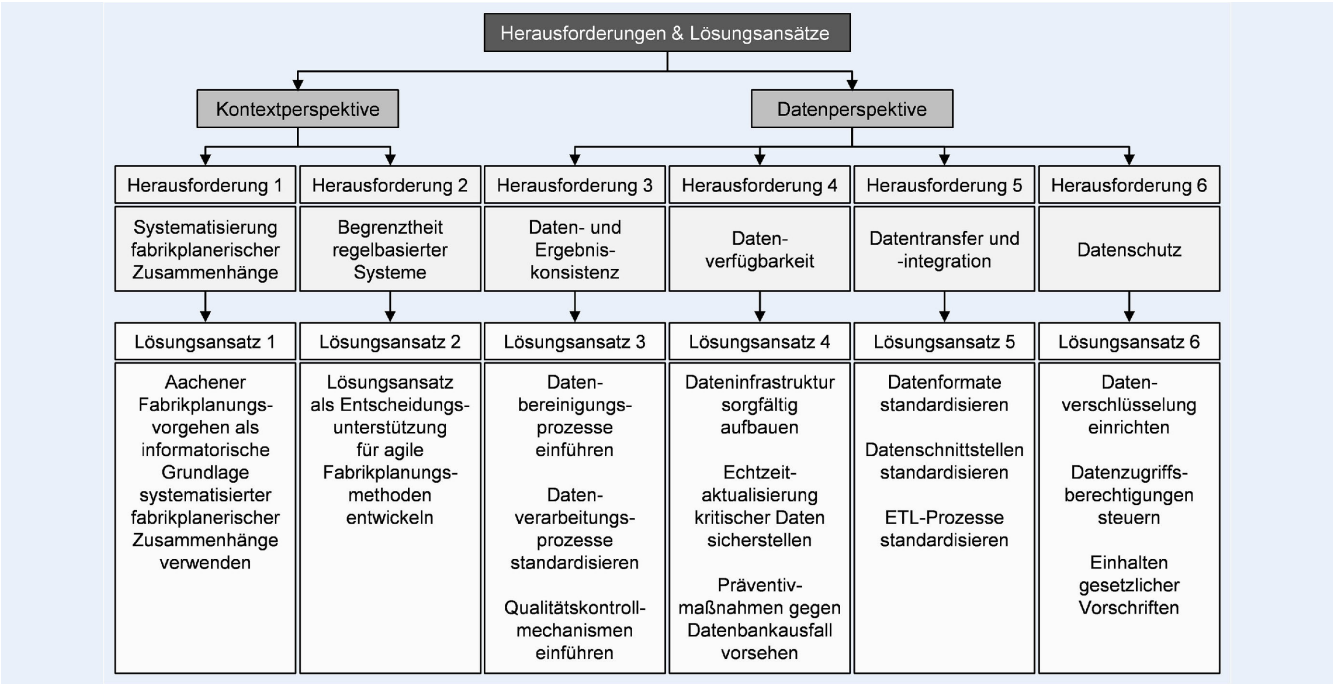


Bild 3. Lösungsansätze für die Anwendung von Data Science zur automatisierten Generierung von Fabrikplanungsergebnissen. Grafik: WZL der RWTH Aachen

- [18] Weber, F.: Künstliche Intelligenz für Business Analytics. Wiesbaden: Springer Fachmedien Wiesbaden 2020
- [19] Pramila P. Shinde; Seema Shah: Fourth International Conference on Computing, Communication, Control and Automation. 16th to 18th August, 2018 : proceedings. Piscataway, NJ: IEEE 2018
- [20] Dinov, I.: Data Science and Predictive Analytics
- [21] Kesavaraj, G.; Sukumaran, S.: A study on classification techniques in data mining. 2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT), Tiruchengode, 2013, S. 1–7
- [22] Solinski, A.; Petersen, K.: Prioritizing agile benefits and limitations in relation to practice usage. Software Quality Journal 24 (2016) 2, S. 447–482
- [23] Burgräf, P.; Dannapfel, M.; Schneidermann, D. et al.: Object attribution for factory information models. Paradigmenwechsel im Fabrikplanungsdatenmanagement]. wt Werkstattstechnik (2019) 109, S. 260–267
- [24] Para, W.; Guerrero, P.; Kelly, T. et al.: Generative Layout Modeling using Constraint Graphs
- [25] Lusti, M.: Regelbasierte Systeme. In: S. 79–122
- [26] Waller, M. A.; Fawcett, S. E.: Data Science, Predictive Analytics, and Big Data: A Revolution That Will Transform Supply Chain Design and Management. Journal of Business Logistics 34 (2013) 2, S. 77–84
- [27] Albrecht, A. J.; Gaffney, J. E.: Software Function, Source Lines of Code, and Development Effort Prediction: A Software Science Validation. IEEE Transactions on Software Engineering SE-9 (1983) 6, S. 639–648
- [28] Haneke, U.; Trahasch, S.; Zimmer, M. et al. (Hrsg.): Data Science. Grundlagen, Architekturen und Anwendungen. Heidelberg: dpunkt.verlag 2021
- [29] Askham, N.; Cook, D.; Doyle, M.: The six primary dimensions for data quality assessment. Defining Data Quality Dimensions
- [30] Zomaya, A. Y.; Sakr, S.: Handbook of Big Data Technologies. Cham: Springer International Publishing 2017

Dr. Michael Riesener 

Dr. Esben Schukat 

Siyuan Wang, M.Sc. 

Alexander Obladen, M.Sc. 

Werkzeugmaschinenlabor WZL
der RWTH Aachen
Campus-Boulevard 30, 52074 Aachen
Tel. +49 151 43117012
a.obladen@wzl.rwth-aachen.de
www.wzl.rwth-aachen.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)