



Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Bachelorthesis

Vor- und Zuname
Dennis Busch

geb. am

■■■■■■■■■■

in

■■■■■■■■

Matr.-Nr:

■■■■■■■■■■

Titel:

**„Bewertung von Data Science und Analytics Methoden in der Produktionsplanung
eines Industrieunternehmens zur Verbesserung der Planungsqualität“**

Abgabedatum:

17.02.2022

Betreuender Professor: Herr Prof. Dr. Henning Kontny

Zweiter Prüfender: Herr Prof. Dr. Axel Wagenitz

Fakultät Wirtschaft und Soziales

Department Wirtschaft

Studiengang:

Logistik / Technische Betriebswirtschaftslehre

Inhaltsverzeichnis

Abbildungsverzeichnis	IV
Abkürzungsverzeichnis	V
Zusammenfassung	VI
1 Ausgangssituation und Problemstellung	1
2 Produktionsplanung nach dem Aachner PPS-Modell	3
2.1 Ziele der Produktionsplanung.....	3
2.2 Kernaufgaben der Produktionsplanung	6
2.2.1 Produktionsprogrammplanung.....	6
2.2.2 Produktionsbedarfsplanung	11
2.2.3 Eigenfertigungsplanung und Fremdbezugsplanung.....	15
2.3 Planungsqualität	20
2.4 Schwachstellen der Produktionsplanung anhand der Planungsqualität.....	22
3 Data Science und Analytics.....	26
3.1 Einführung in die Data Science und Analytics.....	26
3.2 Die Transformation von Big Data zu Smart Data	29
3.3 Maschinelles Lernen.....	33
3.4 Methoden der Datenanalytik	36
3.4.1 Deskriptive Analytik.....	36
3.4.2 Explorative Analytik.....	37
3.4.3 Diagnostische Analytik.....	40
3.4.4 Prädiktive Analytik	40
3.4.5 Präskriptive Analytik	42
4 Bewertung der Data Science Methoden anhand der Planungsqualität einer Produktionsplanung	45

4.1	Matrix zur Untersuchung.....	45
4.2	Diskussion der Kernaufgaben der Produktionsplanung	46
4.2.1	Produktionsprogrammplanung.....	46
4.2.2	Produktionsbedarfsplanung	48
4.2.3	Eigenfertigungsplanung und Fremdbezugsplanung.....	51
5	Fazit und Ausblick.....	56
	Literaturverzeichnis	IV
	Eidesstattliche Erklärung und Einverständnis zur Veröffentlichung	X

Abbildungsverzeichnis

Abbildung 1: Herausforderungen bei KI-Projekten	2
Abbildung 2: Zielsystem der PPS.....	4
Abbildung 3: Aufgabenreferenzsicht.....	7
Abbildung 4: Die Kernaufgaben der Produktionsplanung	8
Abbildung 5: Kapazitätsabstimmung	14
Abbildung 6 Losgrößenberechnung nach Andler.....	16
Abbildung 7: Das Haus der Planungsqualität.....	21
Abbildung 8: Schwachstellen der Produktionsplanung.....	23
Abbildung 9: Datentransformationsprozess	30
Abbildung 10: Data Analysis Prozess	33
Abbildung 11: Künstliches Neuronales Netzwerk	34
Abbildung 12: Aktivierungsfunktion (Sigmoidfunktion).....	34
Abbildung 13: Clusteranalyse	39
Abbildung 14: lineare Regressionsanalyse.....	41
Abbildung 15: Entscheidungsbaum.....	43
Abbildung 16: Matrix zu Untersuchung.....	45
Abbildung 17: Konzept der kognitiven Analytik	59

Abkürzungsverzeichnis

PPS	Produktionsplanung und Steuerung
ERP	Enterprise Resource Planning
MRP	Material Requirements Planning
KI	künstliche Intelligenz
FIR	Forschung, Innovation, Realisierung
RWTH	Rheinisch-Westfälische Technische Hochschule
IT	Informationstechnologie
FIFO	First In, First Out
KOZ	Kürzeste-Operations-Zeit
LOZ	Längste-Operations-Zeit
VUCA	Volatility, Uncertainty, Complexity, and Ambiguity
YARN	Yet Another Resource Negotiator
ID3	Iterative Dichotomiser 3
KPI	Key Performance Indicator

Zusammenfassung

Die Erfassung und Verarbeitung von Daten in großen Mengen ist ein wichtiger Bestandteil für heutige Unternehmen geworden. Vor Allem in der Produktion könnten Datenanalysen dabei unterstützen die Transparenz und Effizienz in einem komplexen Produktionssystem zu erhöhen. Dabei könnte die zentrale Produktionsplanung eines Industrieunternehmens an ausführlichen Datenanalysen besonders profitieren. Trotzdem zeigen Studien, dass es in vielen Unternehmen an den nötigen Kompetenzen zu solch einer Datenwirtschaft fehlt. Die vorliegende Arbeit soll die Kompetenzen im Zusammenhang zur Produktionsplanung darstellen. Zuerst werden die Kernaufgaben der Produktionsplanung betrachtet und Schwachstellen sowie Faktoren zur Planungsqualität untersucht. Daraufhin wird ein Überblick der Data Science und Data Analytics geschaffen, indem auch Technologien wie Big Data, Data Mining und maschinelles Lernen einbezogen werden. Es wird ein Einblick in die unterschiedlichen analytischen Methoden der Data Analytics ermöglicht, um ein erstes Verständnis für die Analyseverfahren und Ziele zu entwickeln. Im Verlauf werden diese Methoden in Bezug zu den Kernaufgaben der Produktionsplanung auf die Verbesserung der Planungsqualität bewertet.

1 Ausgangssituation und Problemstellung

In der heutigen Zeit sind disruptive Technologien ein ständiger Begleiter und können einen erheblichen Schaden an konservativen Geschäftsmodellen verursachen. Aus diesem Grund ist es essenziell, sich weiterzuentwickeln und an diesen disruptiven Technologien zu partizipieren. Eine Lünendonk-Studie hat gezeigt, dass 81% der Unternehmen denken, dass die Schlüsseltechnologie der KI am meisten dazu in der Lage wäre, ihre gesamte Branche disruptiv zu verändern. Trotzdem haben nur 27% der befragten Unternehmen eine dezidierte KI-Strategie entwickelt. Die Frage, die sich stellt, ist, welche Gründe es für diese Entwicklungsmüdigkeit gibt. Eine weitere Erkenntnis der Studie hat gezeigt, dass ein ganzes Spektrum von Hürden dazu führt, dass keine KI-Projekte umgesetzt werden. Die zwei schwerwiegendsten Herausforderungen sind (in Abbildung 1) die Datenverfügbarkeit, Datenqualität sowie Datensilos mit 71% und fehlendes „Data-Science-Know-How“ mit 59%. Dass sich die beiden größten Herausforderungen im Kern mit Daten und der daraus folgenden Erfassung und Verarbeitung von Datenmengen beschäftigen, ermöglicht die Implikation, dass das allgemeine Verhältnis zu Daten und deren Nutzung nicht ausgeprägt genug ist.¹

Es fehlt bei Mitarbeitern und insbesondere im Management schlicht an „Data-Science-Know-How“, obwohl viele Experten auf dem Gebiet erkannt haben, dass Daten das neue Öl der modernen Industrie sind. Aus diesem Grund wird das Thema Data Science und Analytics in vielen Branchen hoch angepriesen und geschult. Auch wenn die Begriffe erst jetzt Präsenz genießen, ist der Begriff der Data Science schon seit 1960 in den Fachkreisen der Informatik geprägt worden. Mit den heutigen Mitteln, Forschungen und entsprechender Hardware ist es möglich, Data Analytics in der allgemeinen Praxis eines Unternehmens zu integrieren und sich somit vor Disruption in der eigenen Branche zu schützen.²

¹ Vgl. Dr. Thomas + Partner GMBH & CO. KG 2019, S. 1 f.; Vgl. Lünendonk, J. 2019, S. 8 f., 17 f.

² Vgl. Chamoni, P. 2021, S. XIII; Vgl. Zgrzebski, W. 2021, S. XI.

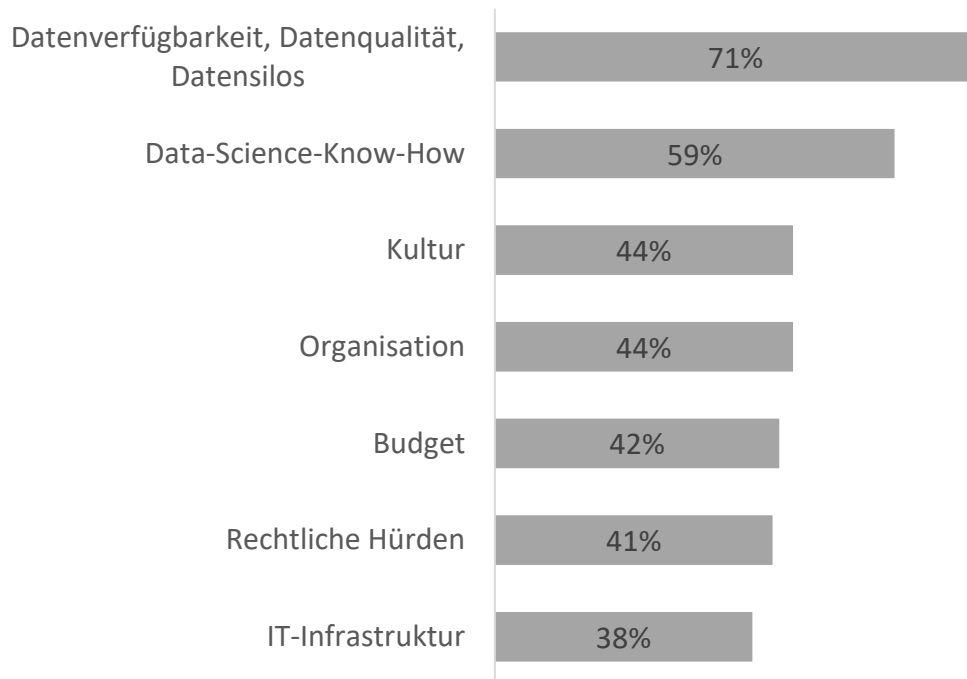


Abbildung 1: Herausforderungen bei KI-Projekten³

Die Verfahren und Modelle der Data Analytics sind in der Lage, mit genügend Daten komplexe Systeme zu analysieren, sodass erstens eine bessere Transparenz möglich ist und zweitens optimale Entscheidungen auf Basis der Datengrundlage getroffen werden können. Ein solches komplexes System ist in vielen Industrieunternehmen in Form des Produktionssystems wiederzufinden. In der klassischen PPS wird dieses System über eine zentrale Planungseinheit organisiert und koordiniert. Dabei ist es schwierig, alle Interdependenzen bei den Planungsentscheidungen zu berücksichtigen, sodass es oft zu Plänen mit Schwachstellen kommt, die hohe Kosten verursachen können.

Um eine bessere Planungsqualität für die PPS zu ermöglichen, könnten die Methoden und Verfahren der Data Science und Analytics verwendet werden. In der folgenden Arbeit sollen die Kernaufgaben der Produktionsplanung vorgestellt und deren Schwachstellen untersucht werden. Es wird ein Einblick in die Data Science und Analytics gegeben, der die Technologien von Big Data und Data Mining sowie das maschinelle Lernen einbezieht. Vor Allem der Prozess, der von unstrukturierter Big Data zur bereinigten und brauchbaren Smart Data führt, ist essenziell für weitere Analyseverfahren. Die Data Analytics bietet unterschiedliche Methoden der Datenanalytik, welche erläutert und anhand einer Auswahl aus den zahlreichen praktischen Verfahren verständlicher vorgestellt werden. Zuletzt wird versucht, die

³ in Anlehnung an Lünendonk, J. 2019, S. 17.

Kernaufgaben der Produktionsplanung mit den Data Analytics Methoden zu vereinen und Vorteile für die Planungsqualität zu identifizieren. Die Ergebnisse dieser Untersuchung werden im Fazit zusammengefasst. Im letzten Kapitel des Ausblicks soll dargestellt werden welche Möglichkeiten neue Technologien im Bereich des Computings die Data Analytics in der Zukunft verändern können und welche neue Analytik Methode damit ermöglicht wird. Das Ziel dieser Arbeit ist es Data Science und Analytics Methoden in der Produktionsplanung eines Industrieunternehmens zur Verbesserung der Planungsqualität zu bewerten.

2 Produktionsplanung nach dem Aachner PPS-Modell

2.1 Ziele der Produktionsplanung

Die Produktionsplanung stellt einen wesentlichen Teil der Produktionsplanung und Steuerung (PPS) dar. Dabei beschreibt das PPS eine sukzessiven, termin-, kapazitäts- und mengenbezogene Planung, um Material und Zeitwirtschaft in der produzierenden Industrie unter einem übergreifenden Konzept zusammenzufassen. Unter diesem sog. Sukzessivplanungsansatz ist zu verstehen, dass die Entscheidungen innerhalb der PPS in den einzelnen Modulen nacheinander getroffen werden. Somit existiert ein vordefinierter Planungsablauf, der im Kapitel der Kernaufgaben nähere Erläuterung findet. In der Regel wird die PPS von einer datenbankgestützten Software begleitet. Dabei werden Daten für präzise Ergebnisse in den Funktionen der Auftragsplanung und -steuerung, die Planung und Durchführung von Produktionsaufträgen bis hin zur Auslieferung der Produkte und der Rechnungsstellung benötigt. Aus diesem Grund gibt es enge Verknüpfungen mit Material Requirements Planning (MRP) und Enterprise Resource Planning (ERP) Systemen.⁴

Die Ziele der Produktionsplanung sind größtenteils von dem Zielsystem der PPS abzuleiten und beinhalten die klassischen logistischen Zielgrößen. Das Hauptziel der PPS ist es, die Profitabilität des Unternehmens und deren Produktion zu maximieren, jedoch ist die Datenverarbeitung und -erhebung zur Optimierung zu komplex und steht nicht im Gleichgewicht mit dem Aufwand. Aus diesem Grund liegt der Fokus auf den Zwischenzielen, welche in Logistikleistungen und Logistikkosten untergliedert sind. Zu den Logistikleistungen zählen externe Faktoren gegenüber den Kunden, wie Lieferzeit und Liefertreue. Unter internen

⁴ Vgl. Schuh, G. et al. 2008, S. 250; Vgl. Schuh, G. et al. 2012d, S. 3; Vgl. Schuh, G. et al. 2012b, S. 29; Vgl. Grabner, T. 2012, S. 203 f.; Vgl. Kellner, F. et al. 2020, S. 139.

Logistikleistungen sind Durchlaufzeit, Terminabweichung und Termintreue zu verstehen. Unter den Logistikkosten sind der Preis für externe Leistungen und auch interne Kosten zu verstehen, welche durch einen erhöhten Bestand, einer niedrigen Kapazitätsauslastung und auftretenden Prozessverzögerungen entstehen.⁵

Die wichtigsten Zielgrößen lassen sich in einem Zielsystem in Abbildung 2 organisieren. Auf der Waagerechten sind die Marktziele orientiert, welche die Interessen der Kunden und des Marktes widerspiegeln. Der Kunde ist daran interessiert, seine Ware innerhalb einer kurzen Lieferzeit zu erhalten. Dabei definiert sich die Lieferzeit als die Zeitdauer zwischen dem Auftragseingang und der Auslieferung der gewünschten Ware. Des Weiteren ist auch die Liefertreue, welche als das Einhalten des Liefertermins zu verstehen ist, für den Markt von großer Bedeutung. Auf der Vertikalen sind die Ziele des eigenen Betriebes angeordnet, zu denen geringe Kosten und Kapitalbindungen mittels geringen Beständen und einer hohen Kapazitätsauslastung gehören. Im Zentrum des Systems treffen beide Interessenlager auf einen Zielkonsens, dabei stehen die hohe Wirtschaftlichkeit des Unternehmens und die damit verbundenen Prozesse im Vordergrund.⁶

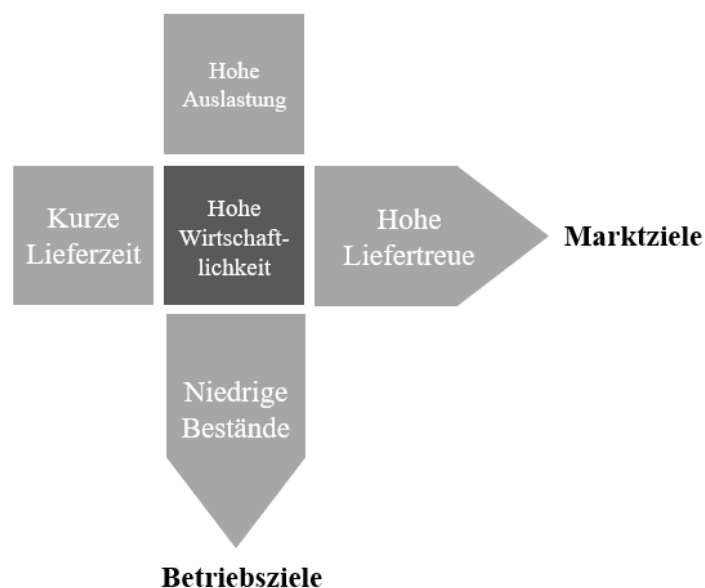


Abbildung 2: Zielsystem der PPS⁷

Jedoch zeigt die aktuelle Entwicklung eine Verschiebung der Ziele, welche hauptsächlich durch die Transformation eines Verkäufermarktes zu einem Käufermarkt entsteht. Die Gründe dieser Transformation sind dabei auf die Internationalisierung und einen erhöhten Konkurrenzdruck

⁵ Vgl. Lödding, H. 2016, S. 21 f.; Vgl. Kellner, F. et al. 2020, S. 131 f.

⁶ Vgl. Sihm, W. et al. 2016, S. 73 f.; Vgl. Lödding, H. 2016, S. 22 ff.

⁷ in Anlehnung an Sihm, W. et al. 2016, Abb. 4.1.

durch einer zunehmenden Marktsättigung zurückzuführen. Die Bedeutung von Marktzielen und dem Kundenservice nimmt stetig zu, sodass eine niedrige Kapazitätsauslastung und hohe Bestände für externe Logistikleistungen, wie etwa Lieferzeit und Liefertreue, in Kauf genommen werden. Die Verschiebung führt zu einem Zielkonflikt, sodass es nicht möglich ist, alle Ziele gleichermaßen einem hohen Erreichungsgrad zuzuschreiben, da gewisse Ziele gegensätzlich sind. Aus Kundensicht werden eine hohe Termintreue, geringe Durchlaufzeiten und eine hohe Flexibilität angestrebt. Jedoch sind diese Ziele oft durch eine geringe oder schwankender Kapazitätsauslastung, hohe Bestände und kostspielige Prozesse in Herstellung und Planung gefährdet. In diesem Fall ist eine Priorisierung der Ziele notwendig, welche sich an die individuelle Lage des Unternehmens und der Marktumgebung anpasst.⁸

Diese praxisnahe Betrachtung des Problems musste mit wissenschaftlichen Beiträgen näher behandelt werden, sodass 1993 am FIR an der RWTH Aachen ein Konzept der PPS erarbeitet wurde, welches sich als „Aachener PPS-Modell“ etabliert hat. Dieses Modell liefert der betrieblichen Praxis eine sinnvolle theoretische Unterstützung. Dabei wird die inner- und überbetriebliche PPS beleuchtet, indem zwischen zwei Aufgabengruppen unterschieden wird und vier verschiedene Referenzsichten bereitgestellt werden. Die Aufgaben-Prozessarchitektur-, Prozess- und Funktionssicht sollen die Transparenz der komplexen PPS-Prozessen verbessern. Im Rahmen dieser Arbeit wird im folgenden Kapitel nur die Aufgabensicht behandelt.⁹

In der Aufgabensicht sind die Kernaufgaben der Produktionsplanung wiederzufinden. Allgemein dient die Produktionsplanung zur Planung der Produktion für die nächsten Planungsperioden. Dazu gehört es, den Inhalt und die Einzelprozesse der Fertigung und der Montage, wie auch die Planwerte für Zugang und Abgang in Einkauf und Versand zu gestalten sowie der Produktionssteuerung Vorgaben nach den logistischen Zielgrößen als Basis für Entscheidungen bereitzustellen.¹⁰

Durch eine überbetriebliche Planung in Wertschöpfungsnetzwerken sind die Aufgaben der Produktionsplanung sehr viel komplexer geworden, sodass Unterstützungen durch vollständige und konsistenten Datenbasen, bestehend aus Stamm- und Bewegungsdaten, nötig sind, um valide Planungsergebnisse sowie sinnvolle Steuerungsentscheidungen generieren zu können. Aus diesem Grund ist auch ein Ziel der Produktionsplanung, eine qualitative Datenverwaltung

⁸ Vgl. Grabner, T. 2012, S. 204; Vgl. Sihn, W. et al. 2016, S. 74 ff.; Vgl. Kellner, F. et al. 2020, S. 132 f.

⁹ Vgl. Schuh, G. et al. 2008, S. 250 ff.; Vgl. Schuh, G. et al. 2012d, S. 5 f.; Vgl. Schuh, G. et al. 2012b, S. 12 f.; Vgl. Grabner, T. 2012, S. 204.

¹⁰ Vgl. Schuh, G. et al. 2008, S. 250; Vgl. Schuh, G. et al. 2012b, S. 29; Vgl. Lötting, H. 2016, S. 107.

anzustreben. Dabei sind Stammdaten als statische Basisdaten von essenzieller Bedeutung, welche als Grundlage der Planung verfügbar sein müssen (z.B. Materialstammdaten, Stücklisten und Arbeitspläne). Hingegen spalten sich Bewegungsdaten durch einen Zeitbezug von den Stammdaten ab, sodass sie durch das tägliche Geschäft teilweise regelmäßige Veränderungen aufweisen. Unter diesen Daten fallen z.B. Bestandsdaten, Bestellungen und Auftragsdaten. Beide Datenarten müssen stets zur Verfügung stehen und eine hohe Aktualität und Datenqualität aufweisen.¹¹

2.2 Kernaufgaben der Produktionsplanung

2.2.1 Produktionsprogrammplanung

Die Produktionsplanung dient dazu, den Inhalt und die Einzelprozesse der Fertigung und der Montage zu gestalten. Es werden Planungsstufen betrachtet, welche von übergeordneten zu untergeordneten Planungsstufen mit zunehmendem Detailierungsgrad geplant werden. Dabei dienen die Planungsergebnisse oft als Vorgabe für die nächstfolgende Stufe. Zur Darstellung der Kernaufgabe wird die Referenzsicht der Aufgaben betrachtet, welche die Aufgaben der PPS in einer allgemeingültigen, hierarchischen und semantischen Abstraktion darstellt. Die Aufgabenreferenzsicht dient dabei zur Abgrenzung von Aufgabenbereichen und Zuordnung der Aufgaben auf die unterschiedlichen Organisationseinheiten des Unternehmens.

In der Abbildung 3 ist die Struktur der Aufgabensicht abgebildet. Allgemein dienen die Aufgaben der PPS zur termin-, kapazitäts- und mengenbezogene Planung und Steuerung der Fertigung und der Montageprozesse. Dabei wird dieser Prozess in drei Aufgabengruppen untergliedert.¹²

¹¹ Vgl. Schuh, G. et al. 2008, S. 255; Vgl. Grabner, T. 2012, S. 207; Vgl. Nyhuis, P. et al. 2014, S. 80.

¹² Vgl. Nyhuis, P. 2008, S. 254 f.; Vgl. Schuh, G. et al. 2012b, S. 21 ff.



Abbildung 3: Aufgabenreferenzsicht¹³

Die innerbetrieblichen Kernaufgaben beschreiben aus Sicht des einzelnen die Arbeitsschritte und Methoden, die für die Planung und Durchsetzung eines Auftrages verwendet werden. Dabei werden die fortschrittschaffenden Aufgaben des eigentlichen Produktherstellungsprozesses abgebildet. Die Kernaufgaben umfassen die Produktionsprogrammplanung, die Produktionsbedarfsplanung, die Eigenfertigungsplanung und -steuerung sowie die Fremdbezugsplanung und -steuerung. Bei der Abwicklung der Kernaufgaben ist zu beachten, dass diese nicht konsequent sequenziell durchgeführt werden. Häufig sind Anpassungen durch Rückkopplungen der vorherigen Schritte vorzunehmen, damit ein optimales Gesamtergebnis erzielt wird.¹⁴

Allen Aufgabenarten der PPS wird ein Bezug zur Datenverwaltung zugerechnet, da alle Aufgaben der PPS bei ihrer Ausführung auf die Datenverwaltung zurückgreifen. Die Nutzung der IT bei Planungs- und Auftragsabwicklungsprozessen hat dabei stark zugenommen, sodass IT-Lösungen in Verbindung mit größeren Datenmengen Anwendung finden. Diese unterstützenden Funktionalitäten sind in Informations- bzw. Anwendungssystemen, welche die Erstellung von Plänen, die Koordination von Abteilungen sowie die Überwachung und Steuerung von Prozessen organisieren, wiederzufinden.¹⁵

¹³ in Anlehnung an Schuh, G. et al. 2012b, Abb. 2.1-5.

¹⁴ Vgl. Schuh, G. et al. 2008, S. 255; Vgl. Schuh, G. et al. 2012b, S. 20; Vgl. Schuh, G. et al. 2012a, S. 38; Vgl. Grabner, T. 2012, S. 204 ff.

¹⁵ Vgl. Schuh, G. et al. 2008, S. 255 ff.

In diesem Kapitel werden die Kernaufgaben lediglich unter Betrachtung der Produktionsplanung dargestellt. Die bedeutet, dass der Aspekt der Steuerung keiner näheren Erläuterung bedarf, sodass im Bereich Eigenfertigung und Fremdbezug nicht auf die Steuerung eingegangen wird. Unter dieser Annahmen werden die Kernaufgaben der Produktionsplanung wie folgt in der Abbildung 4 dargestellt.

Produktionsprogrammplanung	<ul style="list-style-type: none"> • Absatzplanung • Primärbedarfsplanung • Ressourcengrobplanung
Produktionsbedarfsplanung	<ul style="list-style-type: none"> • Sekundärbedarfsermittlung • Beschaffungsartzuordnung • Durchlaufterminierung • Kapazitätsabstimmung
Fremdbezugsplanung	<ul style="list-style-type: none"> • Losgrößenrechnung • Feinterminierung • Ressourcenfeinplanung • Reihenfolgeplanung
Eigenfertigungsplanung	<ul style="list-style-type: none"> • Bestellrechnung • Angebotseinholung/-bewertung • Lieferantenauswahl

Abbildung 4: Die Kernaufgaben der Produktionsplanung¹⁶

In der Produktionsprogrammplanung werden alle herzustellenden Erzeugnisse (Leistungen) nach Art, Menge und Termin für einen definiert Planungszeitraum festgelegt. Das Ergebnis dieser Aufgabe ist ein Produktionsprogramm, das eine Absetzbarkeit über die Nachfrage des Marktes und Realisierbarkeit mittels der verfügbaren Kapazitäten ermöglicht. Die Erstellung des Produktionsprogramms entsteht in einer rollierenden Planung, demnach wird der letzte Plan (z.B. monatlich) um eine Periode in die Zukunft versetzt fortgeführt.¹⁷

Des Weiteren kann der Horizont der Produktionsprogrammplanung sich in einen langfristigen und einen mittelfristigen Zeithorizont unterschieden werden. Die langfristige Produktionsprogrammplanung nimmt eine strategische Rolle ein. Dabei werden grobe Absatzprognosen von zwei bis maximal fünf Jahren als Jahresbedarfe betrachtet und Investitionsentscheidungen innerhalb der Bereiche Produktionsentwicklung, Konstruktion, Kapazitäten und Lieferanten getroffen, sodass der Einfluss auf die zukünftigen Produktionsprogramme abgebildet wird. Trotzdem sind diese Zahlen als sehr spekulativ

¹⁶ in Anlehnung an Schuh, G. et al. 2012a, Abb. 2.2-2.

¹⁷ Vgl. ebenda, S. 39 ff.

anzusehen, da gesamtwirtschaftliche Entwicklungen in Form der Konkurrenz und anderen Produkten nur schwer einzuschätzen sind. Im mittelfristigen Zeithorizont werden die Informationen wesentlich detaillierter über Monate bis hin zu zwei Jahren betrachtet. Dies ermöglicht es, auf Schwankungen innerhalb eines Jahres zu reagieren oder die Kapazitätsauslastung mittels Nivellierung über das Jahr stabil zu halten. Die Prognosen auf Basis von Vergangenheitswerten weisen im Gegensatz zu der langfristigen Sicht eine ausreichende Präzision im Nahbereich auf.

Das Ziel einer zufriedenstellenden Produktionsprogrammplanung ist es, innerhalb der Teilaufgaben eine präzise Absatzplanung zu prognostizieren. Aus dieser Absatzplanung ist der Primärbedarf abzuleiten und die dafür erforderlichen Ressourcen bereitzustellen, um die geplanten Aufträge erfolgreich abzuwickeln. Dies dient dazu, um unter dem Einfluss des logistischen Zielsystems eine hohe Kapazitätsauslastung und geringe Lagerbestände zu erreichen.¹⁸

Unter dem Primärbedarf werden alle verkaufsfähigen Erzeugnisse summiert. Des Weiteren gibt es Sekundärbedarfe und Tertiärbedarfe. Unter die Sekundärbedarfe fallen sämtliche Baugruppen, Komponenten und Rohstoffe, die in der Produktion für verkaufsfähige Erzeugnisse benötigt werden. Über eine Stücklistenauflösung leiten diese sich direkt aus dem Primärbedarf ab. Die Tertiärbedarfe fassen alle niederwertigen Materialien, wie Hilfs- und Betriebsstoffe zusammen.¹⁹

Grundlage für jede Form der Produktionsprogrammplanung ist stets die Teilaufgabe der Absatzplanung, da zuerst der realisierbare Absatz identifiziert werden muss, bevor die Produktion nach Menge und Termin geplant wird. Hierfür stellen prognostizierte Absatzzahlen eine wesentliche Eingangsgröße und Vorgabe der Gewinn- und Umsatzplanung dar. Für Prognosen der Absatzzahlen besteht die größte Bedeutung in der Strategie der kundenanonymen Lagerfertigung. Im Fall einer reinen Einzelauftragsfertigung basiert die Absatzplanung ausschließlich auf festen Kundenaufträgen, was die Komplexität erhöht und flexible Fertigungsprozesse voraussetzt. Dieser Austausch zwischen Logistik, Produktion und Vertrieb versucht eine gewinn- und kostenoptimale Absatz-Produktionsmenge zu ermitteln. Dabei liegt der Fokus zuerst nur auf die verkaufsfähigen Enderzeugnisse, welche unter dem Primärbedarf zu definieren sind.²⁰

¹⁸ Vgl. Grabner, T. 2012, S. 208 ff.; Vgl. Lödding, H. 2016, S. 108 f.

¹⁹ Vgl. Grabner, T. 2012, S. 214.

²⁰ Vgl. Schuh, G. et al. 2012a, S. 40 f.; Vgl. Sihm, W. et al. 2016, S. 84.

Die Ermittlung der zukünftigen Absatzzahlen erfolgt mit Hilfe mathematisch-statistischer Prognosemethoden, wie z.B. ungewichtete, gewichtete bzw. gleitende Mittelwertbildung, exponentielle Glättung erster und zweiter Ordnung, Verfahren nach Winters, Hochrechnung (Extrapolation) oder Verfahren nach Holt. Die Auswahl des geeigneten Verfahrens wird anhand des Absatzverlaufs bestimmt. Des Weiteren wird die Prognose überarbeitet, je mehr man in der Periode voranschreitet, da mit jedem eingehenden Auftrag die auftragsanonymen vorgeplanten Aufträge durch reale Kundenaufträge ersetzt werden. Letztlich soll der Absatzplan den Marktbedarf vollständig und zügig befriedigen, indem die aktuelle und zukünftige Marktlage richtig eingeschätzt wird.²¹

Die zweite Teilaufgabe der Produktionsprogrammplanung widmet sich der Primärbedarfsplanung. Nach dem Sukzessivansatzes sind Grundlagen dafür die Absatzplanung und bereits vorliegende Kundenaufträge, welche gemeinsam die Primärbedarfe bilden. Die Primärbedarfsplanung beschreibt die Planung der Produktion aller verkaufsfähigen Enderzeugnisse oder auch Ersatzteile, sodass dadurch das eigentliche Produktionsprogramm festgelegt wird. Die Summe aller Primärbedarfe ist dann als Bruttoprimarybedarf zu ermitteln. Mit dem Abgleich der verfügbaren Mengen als Lagerbestände wird der Nettoprimärbedarf berechnet, welche die nötige zu produzierende Menge abbildet, um die Nachfrage des Marktes in der aktuellen Planungsperiode zu befriedigen. Das Ergebnis der Primärbedarfsplanung ist ein vorläufiger Produktionsplan mit Nettoprimärbedarfen. Mit der nachfolgenden Teilaufgabe, der Ressourcengrobplanung, wird der Produktionsplan mit den verfügbaren Ressourcen abgestimmt.²²

Die Ressourcengrobplanung hat das Ziel den Absatzplan und den darauf basierenden groben Produktionsplan mit den Restriktionen und den Kapazitäten abzustimmen, um die Machbarkeit des geplanten Absatzes zu überprüfen. Demnach werden Art, Menge und Termin der festgelegten Bedarfe an Erzeugnissen und/oder Ersatzteilen grob eingeplant und mit den verfügbaren Ressourcen, wie etwa Betriebsmittel, Hilfsmittel, Material, Personal und weiteren Kapazitäten, verglichen. Es werden Grobarbeitspläne und Kapazitätsprofile geschaffen. Dabei können auch flexible Änderungen wie Schichtänderungen im Arbeitsplan und Anpassungen im Absatzplan, falls erforderlich durchgeführt werden.²³

²¹ Vgl. Schuh, G. et al. 2012a, S. 42; Vgl. Grabner, T. 2012, S. 209; Vgl. Sihn, W. et al. 2016, S. 83.

²² Vgl. Grabner, T. 2012, S. 205 ff.; Vgl. Schuh, G. et al. 2012a, S. 39 ff.

²³ Vgl. Haasis, H.-D. 2008, S. 207; Vgl. Schuh, G. et al. 2012a, S. 42 f.; Vgl. Grabner, T. 2012, S. 205.

2.2.2 Produktionsbedarfsplanung

Die zweite Kernaufgabe der PPS ist die Produktionsbedarfsplanung. Als Input dient das zu realisierende Produktionsprogramm der vorhergehenden langfristigen Produktionsprogrammplanung. Die Aufgabe der Produktionsbedarfsplanung ist es, die mittelfristigen erforderlichen Ressourcen zu planen, sodass die Realisierbarkeit des Produktionsprogrammes sichergestellt wird. Im ersten Schritt ist es erforderlich den Brutto- und Nettosekundärbedarf an Teilen und Komponenten aus den Primärbedarfen abzuleiten, den Beständen gegenüberzustellen und den zu verwendenden Beschaffungsarten zuzuordnen. Im darauffolgenden Schritt wird die Zeitwirtschaft, die sich in die Durchlaufterminierung, Kapazitätsbedarfsermittlung und Kapazitätsabstimmung einteilen lässt, geplant. Die Ressourcen oder auch Produktionsfaktoren sind Betriebsmittel, Material, Personal, Transportmittel usw., allgemein fallen darunter alle Mittel, die in den betrieblichen Prozess einfließen und als Sekundärbedarf anerkannt werden.²⁴

Die erste Teilaufgabe bezieht sich auf die Sekundärbedarfsermittlung. Das Ziel der Sekundärbedarfsermittlung ist es, die Mengen und Verfügbarkeitstermine für Zukauf- und Eigenfertigungsteile zu bestimmen. Dabei werden in diesem Schritt noch keine Kapazitätsrestriktionen beachtet. Es werden hauptsächlich vier Faktoren berücksichtigt. Die Anzahl der Teile, welche aus Stücklisten, Prognosen oder Einschätzungen gewonnen wird, dazu wird zwischen einer bedarfsorientierten und einer verbrauchsorientierten Ermittlung unterschieden. Die Lagerbestände werden ohne den geplanten Sicherheitsbestand betrachtet. Hierbei wird zwischen Brutto- und Nettosekundärbedarf unterschieden. Der Bruttosekundärbedarf ist die zeitperiodenbezogene Summe an Rohstoffen und Teilen, die für den Produktionsplan erforderlich sind. Der Nettosekundärbedarf ist die Summe der zu beschaffenden oder herzustellenden Rohstoffe oder Teile, dabei werden vom Bruttosekundärbedarf die frei verfügbaren Lagerbestände abgezogen. Die Vorlaufzeiten entstehen daraus, dass der Bedarf eines Teils früher als der Bedarf des zugehörigen Erzeugnisses entsteht. In der Praxis werden diese Zeiten durch Vorlaufverschiebung verringert, indem der Bedarf eines Teils, gegenüber dem des Erzeugnisses zeitlich in Richtung Gegenwart verschoben wird. Bedarfszusammenfassung und Losbildung werden gebildet, um Rüstzeiten

²⁴ Vgl. Haasis, H.-D. 2008, S. 207; Vgl. Schuh, G. et al. 2012a, S. 44; Vgl. Grabner, T. 2012, S. 213; Vgl. Lödging, H. 2016, S. 110.

einzusparen und die Fertigungskapazität zu erhöhen. Daraus resultieren oft erhöhte Bestände, die wiederum keine auftragsorientierte Produktion ermöglichen.²⁵

Zuerst müssen die benötigten Teile einer Beschaffungsart zugeordnet werden, um festzulegen, ob der ermittelte Bedarf durch Eigenfertigung oder Fremdbezug gedeckt werden soll. Es muss somit die Entscheidung getroffen werden, ob Komponenten in der eigenen Produktion oder bei einem Lieferanten hergestellt werden sollen. Dieser Zwiespalt ist unter der Make-or-buy-Problematik bekannt und stellt eine zentrale Entscheidung dar. Die Zuordnung fundiert auf verschiedenen Faktoren. Es werden die nötigen Kapazitäten der Einrichtungen, monetäre Rücklagen für Investitionen in die Produktion und Kostenvergleiche betrachtet. Einer der ausschlaggebendsten Faktoren ist die eigene Kompetenz, als ein Alleinstellungsmerkmal auf dem Markt für technologische Differenzierung zu identifizieren und diese Kompetenzen in der Produktion auszuleben. Dabei können Komponenten, welche keine große Kompetenz benötigen oder Komponenten, bei denen Lieferanten eine höhere Kompetenz als das eigene Unternehmen aufweisen, fremdbezogen werden.²⁶

Des Weiteren werden die Bruttosekundärbedarfe ohne Berücksichtigung der frei verfügbaren Lagerbestände ermittelt. Dafür können drei Ermittlungsverfahren verwendet werden. Das Verfahren mit dem präzisesten Ergebnis und den geringsten Unsicherheiten ist die deterministische Stücklistenauflösung nach einer Bedarfssteuerung. Dieses Verfahren stand jedoch mit einem hohen Aufwand in Verbindung, der heutzutage aber mittels IT-Rechenlösungen stark abnimmt. Die Voraussetzung dafür bilden dafür die Primärbedarfe der vorherigen Kernaufgabe mit Angaben der Mengen und der bereits eingeplanten Termine. Die Zusammensetzung der Erzeugnisse leitet sich aus Stücklisten ab, welche in einem aktuellen und ordentlichen Zustand vorliegen müssen. Eine automatische Stücklistenauflösung erlaubt eine schnelle Soll-Berechnung der kumulierten Bruttobedarfe gleicher Teile. Im Fall der Ist-Werte können durch Schwund und defekten Teilen Schwankungen zur Soll-Berechnung auftreten. Das Verfahren der stochastischen Bedarfsermittlung nach der Verbrauchssteuerung berechnet mittels mathematisch-statistischer Prognosemethoden den zu erwartenden Bedarf auf Basis von Verbrauchswerten der Vergangenheit und ist somit in der Lage einen Bedarf zu ermitteln der Schwund mit einbezieht. Beim heuristischen Verfahren basieren die ermittelten Bedarfe auf den subjektiven Erfahrungen und Einschätzungen der verantwortlichen Disponenten.

²⁵ Vgl. Grabner, T. 2012, S. 218; Vgl. Lödding, H. 2016, S. 110 f.

²⁶ Vgl. Schuh, G. et al. 2012a, S. 46 f.

In der darauffolgenden Teilaufgabe der Produktionsbedarfsplanung werden die Nettosekundärbedarfe für das Produktionsprogramm ermittelt. Dabei wird der Bruttosekundärbedarf unter Berücksichtigung von Lagerbeständen, Reservierungen, Umlauf-, Sicherheits-, Meldebeständen und Bestellungen auf den Nettosekundärbedarf umgerechnet. Der Nettosekundärbedarf ist einer bestimmten Periode zugeordnete Bedarf, der lagerbestandsmäßig verfügbar noch für Aufträge zu Bedarfsdeckung erhalten ist. Mit der Ermittlung des Nettosekundärbedarfes ist der Sekundärbedarf vollständig ermittelt. Neben dem quantitativen Ergebnis der Bedarfe zur Durchführung des Programmplans ist es auch die Aufgabe der Sekundärbedarfsplanung, Fertigungsaufträge mit Endterminen bzw. Startterminen zu organisieren. Diese erste Grobterminierung bildet die Eingangsgröße für die nächste Teilaufgabe der Durchlaufterminierung, welche die Kapazitätsbedarfsermittlung und den Abgleich von Kapazitäten und Belastungen strukturiert.²⁷

Die Durchlaufterminierung stellt einen zeitlichen Zusammenhang zwischen den Fertigungsaufträgen dar, dabei wird versucht Fertigungsaufträge, die eine Beziehung in der Erzeugnisstruktur aufweisen, zur Einsparung von Rüstzeiten aneinanderzureihen. Trotzdem werden im Vergleich zur Produktionssteuerung nur grobe Planungszeiträume festgelegt, sodass als Ergebnis nur Ecktermine, bezogen auf Kapazitätsgruppen, gebildet werden. Beschaffungsaufträge und Eigenfertigungsaufträge werden mittels einer Durchlaufterminierung verplant, indem Zwischentermine je Arbeitsgang aufgrund der technologisch bedingten Arbeitsabläufe festgelegt werden. Bei dieser Durchführung wird hauptsächlich die Durchlaufzeit betrachtet, welche sich auf Belegungszeit (Rüst- und Bearbeitungszeit) und der Übergangszeit (Wartezeit vor und nach der Bearbeitung) zusammensetzt. Dabei werden die Übergangszeiten pauschal oder spezifisch in Abhängigkeit der betroffenen Arbeitsplätze festgelegt.²⁸

Die letzte Teilaufgabe bezieht sich auf die Kapazitätsabstimmung sowie die Kapazitätsermittlung. Im Gegensatz zur Durchlaufterminierung, bei der die Kapazitäten unbegrenzt zur Verfügung standen, werden in dieser Teilaufgabe die Kapazitäten begrenzt und mit abgestimmt. Der Begriff der Kapazität beschreibt dabei das Leistungsvermögen eines Arbeitssystems, in dem Maschinen, Personal, Werkzeuge oder Transportfahrzeuge vorhanden sind, welche die Begrenzungen mit sich bringen. Speziell für die Kapazitätsplanung werden Kapazitätsprofile oder Grobarbeitspläne berechnet und aufbereitet, sodass Einlastungen von

²⁷ Vgl. ebenda, S. 46 f.; Vgl. Lödding, H. 2016, S. 111.

²⁸ Vgl. Schuh, G. et al. 2012a, S. 48; Vgl. Grabner, T. 2012, S. 223.

Aufträgen ergebende Kapazitätsbedarfe für einzelne Ressourcen oder Kapazitätsgruppen ermittelt werden können. Für die Ermittlung werden die terminierten Arbeitsgänge der Durchlaufterminierung pro Planungsperiode betrachtet und jeweils die Stückzeiten mit den Stückzahlen multipliziert. Die Stückzeiten enthalten die Bearbeitungszeit, mit der die dem Arbeitsgang zugeordnete Kapazität belastet wird. Allgemein lassen sich die Kapazitätsbedarfe durch Anpassung von Lieferzeiten, kleinere Auftragsmengen und durch höhere Lagerbestände steuern. Nach der Ermittlung der Bedarfe für jegliche Arbeitsgänge, werden diese pro Planungsperiode summiert. Als Ergebnis entsteht der Kapazitätsbedarfsplan, aus dem für jede Kapazitätseinheit die Kapazitätsbedarfe pro Planungsperiode ersichtlich sind.²⁹

Um den Kapazitätsplan mit den Planperioden zur organisieren, müssen Kapazitätsgrenzen eingehalten werden. Die Kapazitätsabstimmung dient dazu, den aufsummierten Kapazitätsbedarf pro Planungsperiode dem vom Unternehmen zur Verfügung gestellten Kapazitätsangebot gegenüberzustellen und abzustimmen. In der Abbildung 5 werden drei Abstimmungsarten vorgestellt.

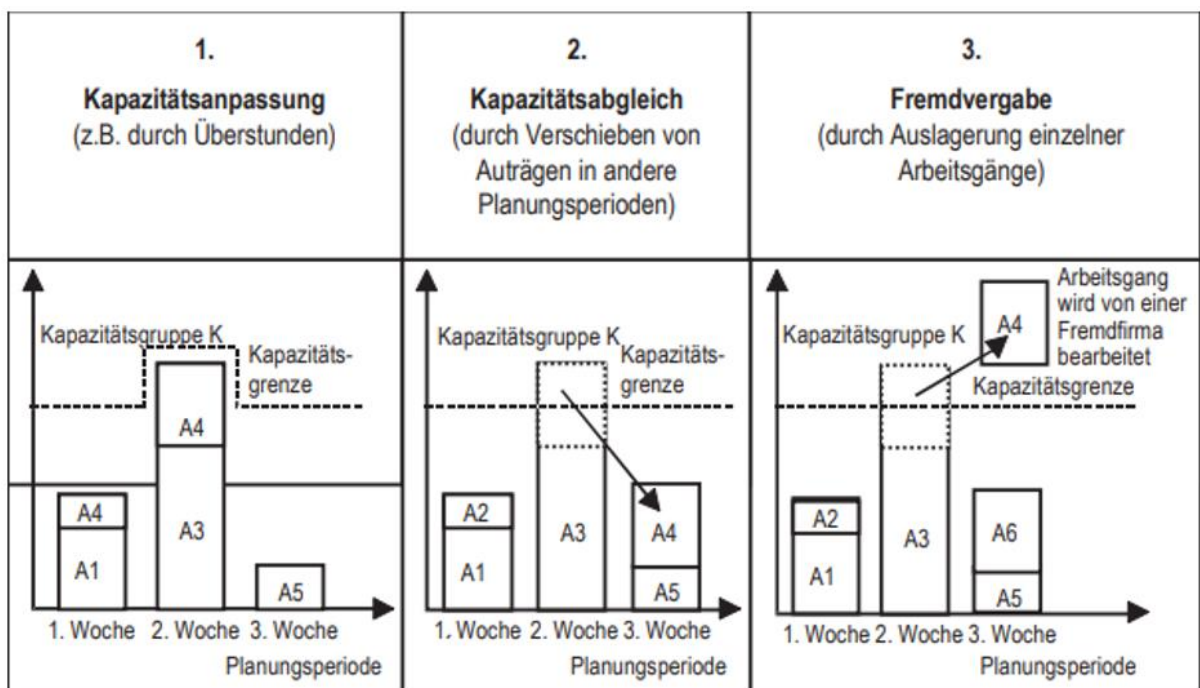


Abbildung 5: Kapazitätsabstimmung³⁰

Es können Kapazitätsanpassungen durchgeführt werden, sodass kurzfristig oder auch langfristig das zur Verfügung gestellte Angebot von Kapazität angehoben wird. Geeignete Maßnahmen wären die Einführung von Überstunden, mehr Schichten, Nutzen alternativer,

²⁹ Vgl. Grabner, T. 2012, S. 224; Vgl. Schuh, G. et al. 2012a, S. 49.

³⁰ Vgl. Schuh, G. et al. 2012a, Abb. 2.2-12.

neuer Betriebsmittel etc. Beim Kapazitätsabgleich werden die Spitzenbedarfe, welche die Kapazitätsgrenze in einer Periode überschreiten auf andere Perioden mit noch freien Kapazitäten umgeschichtet. Sollten das summierte Kapazitätsangebot des Unternehmens nicht ausreichen, gibt es auch die Möglichkeit die Aufträge einem Lieferanten zu übertragen.³¹

2.2.3 Eigenfertigungsplanung und Fremdbezugsplanung

In der Eigenfertigungsplanung und Fremdbezugsplanung werden einerseits die endgültige Menge eines Fertigungsauftrages und die Feinplanung der Termine festgelegt und andererseits werden Lieferanten gewählt und Bestellvorgänge veranlasst, welche die Verfügbarkeit der Fremdbezugsmaterialien sicherstellen.

Im Rahmen der Eigenfertigungsplanung sollen mithilfe der Ergebnisse der Produktionsbedarfsplanung die Reihenfolge der Aufträge für die einzelnen Arbeitsplätze bestimmt werden. Dabei spielt der Dispositionsspielraum, welcher sich aus der Differenz von frühesten und spätesten möglichen Startterminen der Fertigung berechnet, eine wichtige Rolle. Im Fall eines frühen Starttermins der Fertigung und somit eines erhaltenden Dispositionsspielraums, kommt es oft zu erhöhten Beständen und unnötig langen Durchlaufzeiten. Im Fall eines späten Fertigungsstarts sind Bestände und Durchlaufzeiten zwar gering, jedoch weist die Produktion eine hohe Störanfälligkeit und eingeschränkte Rüstooptimierungen auf. Ziel ist es, in diesem Zwiespalt zwischen Wirtschaftlichkeit und Risiko ein Optimum für das Unternehmen zu identifizieren. Zwar lässt sich die simultane Planung von Terminen und Kapazitäten in einer mathematisch, optimierenden Nutzenfunktion lösen, jedoch ist dieser Schritt mit einem hohen Rechenaufwand verbunden. Eine komplexe Herausforderung, die mit einem hohen Rechenaufwand zusammenhängt, zeigt sich dann auf, wenn durch Probleme am Prozess Pläne überarbeitet werden müssen und sich diese Veränderungen mittels verschiedener Interdependenzen auf andere Arbeitsplätze auswirken. Sehr viel flexibler könnten diese Schwierigkeiten mit einer kleinen Losgröße angegangen werden. Die Losgrößenberechnung ist die erste Teilaufgabe der Eigenfertigungsplanung, weitere Bestandteile sind die Feinterminierung, die Ressourcenfeinplanung sowie die Reihenfolgeplanung.³²

³¹ Vgl. ebenda, S. 49 f.; Vgl. Lödning, H. 2016, S. 224 ff.

³² Vgl. Grabner, T. 2012, S. 228; Vgl. Schuh, G. et al. 2012a, S. 51 ff.

Die Losgröße beschreibt Fertigungslose, welche einem Fertigungsbereich zugeordnete Arbeitsgänge jeweils nach ihrer Menge aufteilen. Ziel ist es eine wirtschaftlich optimale Losgröße zu berechnen. Dafür gibt es verschiedene unternehmerische Zielsetzungen. Die meisten Losgrößenverfahren zielen darauf ab, die losgrößenabhängigen Kosten, wie Rüst- und Bestandskosten, zu minimieren. Rüstkosten entstehen durch das Umrüsten einer Maschine. Dieses Umrüsten dient dazu, durch z.B. den Austausch des eingesetzten Werkzeuges andere Produktvarianten produzieren zu können. Dieser Prozess verlangt Zeit in Form von Arbeitszeit des Personals und der nicht genutzten Zeit der Maschine, die letztlich als ungenutzte Kapazität erkannt wird. Mittels einer hohen Losgröße werden die sortenreinen Fertigungsaufträge zusammengefasst, sodass weniger umgerüstet werden muss. Bestandskosten orientieren sich an der Höhe des durchschnittlichen Warenbestandes, wie auch Umlaufbestandes und werden über das gebundene Kapital und einem kalkulatorischen Zins berechnet, gleichzeitig fallen Lagererhaltungskosten an. Die allgemeinen Bestände lassen sich mit einer geringen Losgröße verringern. Diese Verhältnis zwischen Bestandskosten und Rüstkosten lässt sich in der Abbildung 6 zusammenfassen.³³




Abbildung 6 Losgrößenberechnung nach Andler³⁴

³³ Vgl. Grabner, T. 2012, S. 229; Vgl. Lödding, H. 2016, S. 115.

³⁴ Vgl. Grabner, T. 2012, Abb. 6.19.

Das Grundverfahren von Andler berechnet die Losgröße. Summiert man beide Kosten, so ergibt sich eine Funktion, bei der das Kostenminimum berechnet wird, welches als kostenoptimale Losgröße (x_{opt}) bezeichnet wird. Des Weiteren gibt es weiterentwickelte Verfahren wie z.B. die durchlauforientierte Losgrößenbestimmung, welche die Kapitalbindungskosten innerhalb der Produktion während der Übergangszeiten und Auftragsbearbeitung einbeziehen. Dies führt zu einem steileren Anstieg der Zins- und Lagererhaltungskostengerade, sodass die optimale Losgröße kleiner ausfällt. Allgemein ist bei allen Verfahren am Ort der optimalen Losgröße ein flacher Verlauf der Funktion vorzufinden, bei dem Losgrößenveränderungen keine extremen Auswirkungen auf die Kosten haben. Aus diesem Grund werden Losgrößenformeln in der Praxis oft als Richtwerte hinzugezogen, sodass die Losgrößen vor dem Erfahrungshintergrund der Mitarbeiter einmalig intuitiv festgelegt werden.³⁵

Wenn die Losgröße festgelegt ist, folgt die nächste Teilaufgabe, die Feinterminierung genannt wird. Diese ermittelt mit den berechneten Losgrößen die Start- und Endtermine der Arbeitsgänge neu, sodass die Arbeitsvorgänge in zeitgenauer Reihenfolge auf die Betriebsmittel abgestimmt sind. Sicherlich liegt die Durchlaufterminierung der Produktionsbedarfsplanung bereits vor, jedoch können Verzögerungen, wie höhere Bearbeitungszeit, Störungen und Lieferverzögerungen dazu führen, dass das Kapazitätsangebot immer schmaler wird und die Durchlaufterminierung umgeworfen werden muss.³⁶

Allgemein lässt sich die Feinterminierung in drei Unterschritte aufspalten. Als Erstes werden die Ergebnisse der Losgrößenberechnung überprüft und, falls erforderlich, Anpassungen an den Aufträgen vorgenommen. Daraufhin werden während des aktiven Betriebes immer wieder die Fertigungsdaten aktualisiert, damit die freigegebenen Aufträge dauerhaft an die Zeit- und Kapazitätsbedarfe der momentanen Fertigungssituation angepasst werden können. Als Hauptaufgabe der Feinterminierung wird die Maschinenbelegungsplanung angesehen. Sie legt die Reihenfolge fest, in der die Aufträge mit ihren Arbeitsgängen auf den Fertigungsanlagen nacheinander abgearbeitet werden.³⁷

Dafür ist es essenziell, dass den Arbeitsgängen Übergangszeiten und Bearbeitungszeiten zugeordnet werden, damit die Summe der Durchlaufzeiten ermittelt werden kann und die Terminierung präzise stattfindet. Das Ergebnis der Feinterminierung sind detaillierte Belegungspläne der Bearbeitungssysteme, welche Start- und Endtermine der Aufträge

³⁵ Vgl. Nyhuis, P. 2008, S. 212 f.; Vgl. Grabner, T. 2012, S. 229, 232; Vgl. Lödding, H. 2016, S. 115.

³⁶ Vgl. Grabner, T. 2012, S. 233; Vgl. Schuh, G. et al. 2012a, S. 54; Vgl. Lödding, H. 2016, S. 116.

³⁷ Vgl. Haasis, H.-D. 2008, S. 209.

enthalten. Aus diesen Plänen lassen sich schließlich auch Personal- und Werkzeugpläne ableiten.³⁸

Die dritte Teilaufgabe der Eigenfertigungsplanung widmet sich der Ressourcenfeinplanung. Hier werden im Gegensatz zur Feinterminierung wieder die Kapazitäten, also die Ressourcen berücksichtigt, sodass die vorherige Planung durch neue Prämissen korrigiert wird. Die Ressourcenfeinplanung soll dazu dienen, die Verfügbarkeit der erforderlichen Kapazitäten sicherzustellen. In diesem Fall sind unter Ressourcen das Material und die Kapazitäten an Personal, Betriebsmitteln und Hilfsmitteln zu verstehen. Ähnlich wie bei der Kapazitätsabstimmung wird das Kapazitätsangebot mit dem Kapazitätsbedarf gegenübergestellt. Dabei entspricht der Kapazitätsbedarf der Summation der Belegungszeiten pro Kapazität und Planungszeiteinheit. Die Kapazitätsabstimmung hat das Ziel, eine gleichmäßige Kapazitätsauslastung zu schaffen, die mit denselben Kapazitätsanpassungen wie in der Produktionsbedarfsplanung erreicht wird.³⁹

Im Rahmen der letzten Teilaufgabe, der Reihenfolgeplanung, wird die Reihenfolge neu angesetzt, dabei wird die Reihenfolgebildung anhand sog. Prioritätsregeln festgelegt. Dies ist eine einfache Lösung, die keinen großen Planungsaufwand in Anspruch nimmt, jedoch reichen diese Regeln oftmals nicht aus, um die logistische Zielsetzung befriedigend zu erfüllen. Dabei können unterschiedliche Regeln verfolgt werden: FIFO-Prinzip, KOZ-Regel, LOZ-Regel und Schlupf-Zeitregel. Schließlich kann mit erhöhtem Aufwand auch eine optimale Reihenfolge ermittelt werden. Die Aufträge werden dabei terminlich auseinandergereiht, sodass der Rüstaufwand minimiert werden kann, jedoch führt das dazu, dass Einzelaufträge zeitlich vorgezogen werden.

Neben der Nutzung von Prioritätsregeln kann auch eine interaktive Feinterminierung mit Leitständen realisiert werden. Dabei werden elektronische Leitstände visualisiert, welche die Zuordnung der Arbeitsvorgänge zu den Betriebsmitteln darstellen. Die Produktionsplaner sind somit in der Lage, die Aufträge interaktiv umzuplanen.⁴⁰

Die Eigenfertigungsplanung beschäftigt sich mit der Planung der Fertigung von Komponenten und fertigen Erzeugnisse in der eigenen Produktion. Neben dieser Quelle für Teile besteht auch die Möglichkeit, Teile von Lieferanten zu beziehen. In diesem Fall wird eine Fremdbezugsplanung durchgeführt. Die Fremdbezugsplanung stellt das vorab im Rahmen der

³⁸ Vgl. ebenda, S. 209; Vgl. Schuh, G. et al. 2012a, S. 54.

³⁹ Vgl. Schuh, G. et al. 2012a, S. 50 ff.

⁴⁰ Vgl. Lödding, H. 2016, S. 117; Vgl. Wiendahl, H.-P./Wiendahl, H.-H. 2020, S. 233 ff.

Produktionsbedarfsplanung generierte Fremdbezugsprogramm dar. Darunter werden alle fremd zu beschaffenden Stoffe bzw. Bauteile, Unterbaugruppen, Baugruppen und/oder Module aus qualitativer, quantitativer und zeitlicher Perspektive gesteuert. Gegenstände dieser Kernaufgabe sind die Bestellrechnung, Angebotseinholung/-bewertung und die Lieferantenauswahl.⁴¹

Das Ziel der Bestellrechnung ist die Ermittlung der wirtschaftlich optimalen Bestellmenge, sodass die Bedarfe quantitativ und zeitlich gedeckt sind. Bei dieser Betrachtung kann analog das Grundmodell von Andler zur Optimierung der Bestellmenge als Hilfe herangezogen werden. Aus der Perspektive der Beschaffung werden die Faktoren der Bestellkosten (Transport, Versicherung, usw.) und die Lagererhaltungskosten summiert und ein Kostenminimum ermittelt. Weitere Aspekte wie Lagerfähigkeit der Ware sowie Liquidität des eigenen Unternehmens werden bei der Entscheidung über die optimalen Bestellmenge mit einbezogen. Des Weiteren ist die Lieferfähigkeit des Lieferanten ausschlaggebend. Die Einholung von näheren Informationen wird über die zweite Teilaufgabe, die Angebotseinholung und -bewertung durchgeführt. Wenn die Bedarfe zum ersten Mal auftreten, muss als nächster logischer Schritt erst ein geeigneter Lieferant gewählt werden. Dafür werden Angebote von mehreren potenziellen Lieferanten eingeholt. Diese Angebote werden im Hinblick auf bestimmte Kriterien begutachtet und dienen als Grundlage für die Lieferantenauswahl. Die Lieferantenauswahl muss mit der Bestellmengenrechnung abgeglichen werden, da jeder Lieferant andere Lieferkonditionen besitzt, sodass die vorangenen Kostenstrukturen möglicherweise nicht mehr übereinstimmen und angepasst werden müssen. Basierend auf der Lieferantenbewertung werden die Lieferanten hinsichtlich der Kriterien Qualität, Liefertermintreue sowie Preisen und Lieferkonditionen bewertet. Wenn der Hauptlieferant gewählt wurde, werden Rahmenvereinbarungen geschlossen, welche über einen längeren Zeitraum hin Abnahmemengen und Konditionen festlegen.⁴²

⁴¹ Vgl. Haasis, H.-D. 2008, S. 209; Vgl. Lödning, H. 2016, S. 7.

⁴² Vgl. Schuh, G. et al. 2012a, S. 58 ff.

2.3 Planungsqualität

Um allgemein eine Planung qualitativ bewerten zu können, muss zuerst der Prozess einer Planung betrachtet werden. Eine wichtige Entscheidung in einem komplexen System zu treffen, ist eine herausfordernde Aufgabe und verlangt hohe Aufmerksamkeit für die aktuelle und zukünftige Datenlage. Da die Entscheidungsfindung eine hohe Verantwortung mit sich bringt, ist eine ausführliche Vorbereitung nötig, die in Form der Planung stattfindet. Die Planung unterstützt die Entscheidungsfindung, indem Alternativen von zukünftigen Aktivitäten identifiziert und anschließend bewertet werden, sodass die möglichst optimale Alternative ausgewählt werden kann. Der allgemeine Planungsprozess aus insgesamt fünf Einzelschritten: die Anerkennung und Analyse des eigentlichen Entscheidungsproblems, der Definition der Alternativen, die Prognose von zukünftigen Entwicklungen, die Identifizierung und Evaluation von potenziellen Lösungsansätzen und die Auswahl einer guten oder einer ggf. optimalen Lösung.

Während die Analyse des Entscheidungsproblems und die Auswahl der umzusetzenden Lösung die Fragestellung und das Ergebnis darstellen, sind die Definition und Evaluation der Alternativen, sowie die Prognosen der zukünftigen Datenlage die Teilaufgaben, bei denen in der aktuellen Zeit größere Schwierigkeiten auftreten. Eine qualitativ hochwertige Planung sollte in der Lage sein, die Schwierigkeiten so weit wie möglich kontrollieren zu können. Die erste Schwierigkeit wirkt sich auf die Definition der Alternativen aus. In komplexen Systemen, wie etwa einer Produktion, sind Entscheidungsalternativen nicht zwischen der Entscheidung A und der Entscheidung B zu differenzieren. Die Entscheidungen der Produktion, wie etwa die Terminierung von Aufträgen, weisen ein weitreichendes Spektrum an nahezu unendlich vielen Alternativen auf. Dies führt dazu, dass ein Großteil der möglichen Alternativen nicht beachtet werden, da eine genaue Evaluation aller dieser Alternativen einen zu hohen Planungsaufwand mit sich bringt. Zweitens sind die Kriterien, die eine Evaluation mit sich bringt, oft mehrdeutig oder weisen ein konkurrierendes Verhältnis zueinander auf, sodass eine zufriedenstellende Lösung für jegliche Kriterien schwierig umzusetzen ist. Die Dritte und härteste Schwierigkeit ergibt sich aus den Unsicherheiten der heutigen Welt gegenüber den Prognosen, aus denen jeweils das Fundament der meisten Planungen gebildet wird.⁴³

⁴³ Vgl. Fleischmann, B. et al. 2015, S. 71 ff.

In der heutigen Wirtschaftsumgebung, die auch als sog. VUCA-Welt bezeichnet wird, spielen Faktoren wie Volatilität, Unsicherheit, Komplexität und Mehrdeutigkeit eine immer größere Rolle und beeinflussen die Prognosefähigkeit erheblich. Volatilität bezeichnet in dem Zusammenhang mit dem aktuell fast zeitgleichen Datenaustausches die ständige Veränderung der Datenlage, was für die Planungs- und Prognosefähigkeit fatale Auswirkungen haben kann. Innerhalb dieser Problematik ist es wichtig Flexibilität zu gewährleisten, indem z.B. rollierende und kurze Planungshorizonte eingehalten werden, die so schnell wie möglich neue Daten einbeziehen. Hinzu kommen Unsicherheiten der Daten, sodass es nicht leicht festzustellen ist, ob die jeweiligen Daten überhaupt einen signifikanten Einfluss auf die Planung haben können. Komplexität stellt die Vielzahl der agierenden und vernetzten Subsysteme dar, die auch in der Produktion wiederzufinden sind. Die Mehrdeutigkeit gestaltet eine ernstzunehmende Entscheidungsfindung schwierig, da die Auswirkungen oft undurchsichtig sind. Erfahrungen hierzu können nur durch Experimente oder Simulationen erlangt werden.⁴⁴

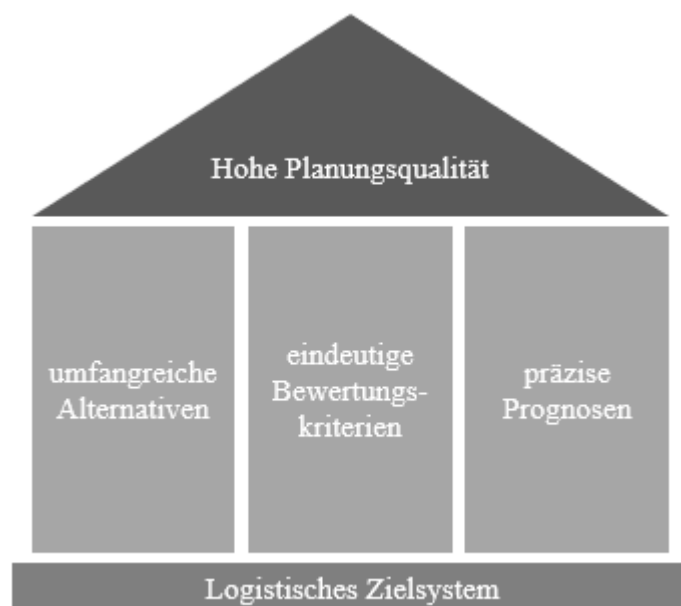


Abbildung 7: Das Haus der Planungsqualität⁴⁵

Da nun der Planungsprozess definiert ist und die allgemeinen Schwierigkeiten für eine hohe Planungsqualität bewältigt werden müssen, dienen sie als tragende Säulen für eine hohe Planungsqualität, wie in Abbildung 7 dargestellt. Nun wird die logistische Perspektive eingenommen und die Produktionsplanung berücksichtigt. Das allgemeine Ziel der Produktionsplanung ist, die logistischen Zielgrößen einzuhalten, woraus sich die Höhe der

⁴⁴ Vgl. Bennett, N./Lemoine, G.J. 2014, S. 3 f.

⁴⁵ Eigene Darstellung

Planungsqualität ableiten lässt. Demnach müssen die Alternativen, Kriterien und Prognosen der Planung so ausgerichtet werden, dass eine optimale Lösung zwischen den Zielen hohe Termintreue, hohen Servicegrad, hohe und gleichmäßige Kapazitätsauslastung, kurze Durchlaufzeiten, geringe Lager- und Werkstattbestände und hohe Flexibilität erreicht wird. Das Anstreben der logistischen Zielgrößen dient als Fundament des Planungsprozesses und soll diesen kontinuierlich begleiten, wie in der Abbildung 7 zu erkennen ist. Auf den ersten Blick wird klar, dass die o.g. Schwierigkeiten auch die logistischen Zielgrößen beeinflussen. Erstens herrschen konkurrierende Kriterien, wie etwa eine hohe Flexibilität bei geringen Lagerbeständen. Zweitens weisen alle Entscheidungen zur Erfüllung der logistischen Zielgrößen ein umfangreiches Alternativenspektrum auf. Drittens basiert die Produktion und der Servicegrad auf den prognostizierten Werten der Absatzprognose, welche den Startpunkt und das Fundament der sukzessiven Produktionsplanung bilden. Letztendlich muss es das Ziel einer qualitativ hochwertigen Planung sein, präzise Prognosen in Zeiten von Volatilität und Unsicherheit regelmäßig aufstellen zu können und zwischen unzähligen Alternativen eine gut bewertete Entscheidung mittels eindeutigen Kriterien zu treffen, sodass auch unter konkurrierenden Zielgrößen eine optimale Lösung entsteht.⁴⁶

2.4 Schwachstellen der Produktionsplanung anhand der Planungsqualität

Das Aachener PPS-System wurde im Jahr 1993 entwickelt, sodass heutige Möglichkeiten und Herausforderungen Schwachstellen des Systems hervorheben, welche die Planungsqualität beeinflussen. In der heutigen Situation stellen sich Unternehmen dem Problem, mit neuen Rahmenbedingungen der Globalisierung, der Technik und der Gesellschaft umzugehen. Diese Neubetrachtungen zeigen Schwachstellen in der PPS auf, die durch eine Reorganisation verringert werden könnten. Durch die Globalisierung und die zunehmende Verknüpfung aller Unternehmensaktivitäten und der zentralen Koordination durch das PPS-System, sind die Kernaufgaben der PPS wesentlich komplexer geworden. Im Bereich der Produktionsplanung können einige Probleme mit Einfluss auf das Ergebnis der Produktionsqualität identifiziert werden.⁴⁷ Eine Übersicht der vorgestellten Schwachstellen wird in der Abbildung 8 dargestellt.

⁴⁶ Vgl. Schuh, G. et al. 2012a, S. 29; Vgl. Fleischmann, B. et al. 2015, S. 71 ff.

⁴⁷ Vgl. Schuh, G. et al. 2012c, S. 297.

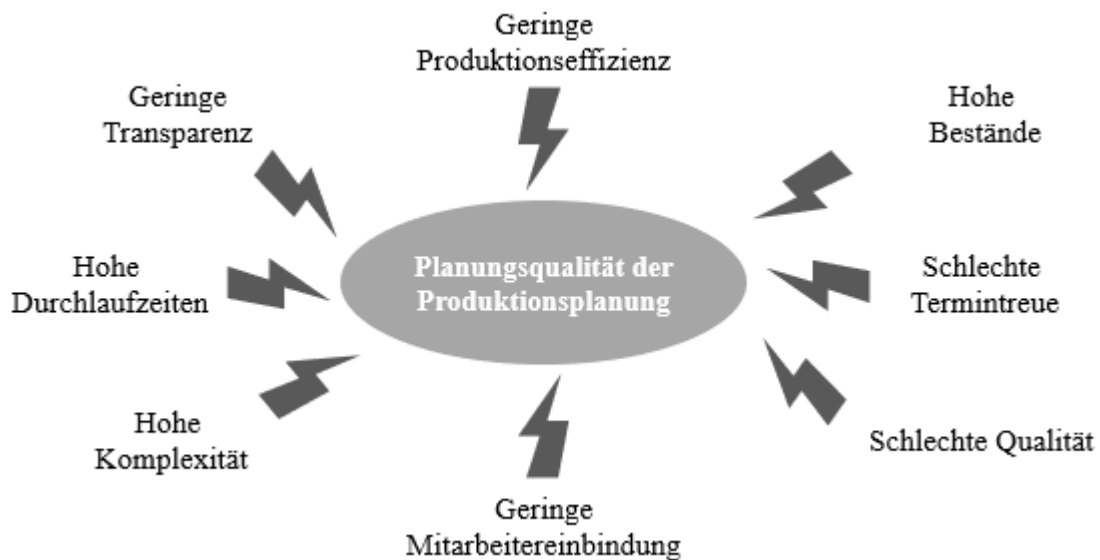


Abbildung 8: Schwachstellen der Produktionsplanung⁴⁸

Die schwerwiegendste Schwachstelle ist die Transparenz im ganzen System sowie auf den tiefsten und damit operativsten Ebenen. Die Aufgaben der PPS benötigen eine vollständige konsistente Datenbasis, bestehend aus Stamm- und Bewegungsdaten, um valide Planungsergebnisse generieren und Steuerungsentscheidungen treffen zu können. In diesem Punkt scheitert es oft in der Praxis an der Datenqualität der Stamm- und Bewegungsdaten. Die Schwächen befallen in Bezug auf Datenaktualität, Datenauflösung sowie Datenkonsistenz beide Varianten gleich schwer und entsprechen nicht den Anforderungen der Aufgaben der PPS. Darüber hinaus benötigen Entscheidungen innerhalb der Feinterminierung echtzeitbasierte Daten und Datenanalysen, die einen hohen Aufwand auslösen können.

Ein wesentlicher Grund für dieses Defizit liegt in der mangelnden Integration der IT-Unterstützungssysteme. Daraus folgt, dass der Produktionsplanung nicht der Zugang zu den wichtigen Informationen über alle Produktionsbereiche und -ebenen gewährt wird. Des Weiteren wird ein Großteil von Rückmeldungen und Produktionsdaten immer noch schriftlich und nicht in digitaler Form übermittelt. Dabei gibt es Daten, die oft zwangsweise manuell von den Mitarbeitern erfasst und in das System eingespeist werden müssen. Besonders anfällig ist das bei maschinen- und anlagenintensiven Produktionsbereichen, sodass wichtige Daten, wie etwa Stillstandzeiten, Rüstzeiten und Taktzeitverlustzeiten, nicht erfasst werden und somit auch nicht in der PPS berücksichtigt werden können. Hinzu kommt, dass die Zugänglichkeit, Nutzung und Akzeptanz einer ausführlichen Datenwirtschaft innerhalb eines

⁴⁸ Eigene Darstellung

Produktionssystemen den Mitarbeitern nicht verständlich vermittelt wird. Diese Aspekte machen es schwierig, eine echtzeitfähige Abbildung von Produktionssystemen zu generieren, sodass Planungen und Entscheidungen innerhalb der PPS nicht optimal durchgeführt werden können.⁴⁹

Hinzu kommt, dass die Komplexität eines Produktionssystems in eine fast unkontrollierbare Höhe angestiegen ist. Aufgrund der Vielzahl von zu berücksichtigenden Planungsobjekten, wie Rohstoffe, Zwischen- und Endprodukte, Maschinen und Personal sowie der zahlreichen Interdependenzen zwischen den Entscheidungen, ist es nicht möglich eine Planung in Bezug auf eine maximierte Profitabilität auszuführen. Die Analyse und der Umfang der Erhebung der dafür benötigten Daten ist zu komplex. Hinzu kommt die Sicherheit der generierten Daten, die sich zu jeder Zeit durch Störungen oder Krankheitsfällen schlagartig ändern können, sodass die aufwendige Planungsarbeit hinfällig wird.⁵⁰

Eine weitere Schwachstelle ist in der Effizienz zu erkennen, vor allem bei der Optimierung von Rüstzeiten, der Arbeitsplatzplanung und der Reaktion auf Maschinenstörungen. Bei den Rüstzeiten ist die Organisation in der Praxis unkoordiniert, da nicht alle Mitarbeiter rechtzeitig über anstehende und oft kurzfristig geplante Rüstvorgänge informiert werden. Diese mangelhafte Struktur beim Rüstvorgang kann insbesondere auch mit einer optimierten, vorher festgelegten Reihenfolge verbessert werden. Die Verbesserungspotenziale, welche durch eine bessere Planung und Koordination erreicht werden können, sind in der Praxis enorm und verkürzen die Rüstzeiten um 50% bis 70%. Die Arbeitsplatzplanung erfolgt oft oberflächlich und wird oft über viele Produktgenerationen hinweg nur kopiert und nicht an die Realität angepasst. Doch gerade bei den Vorgabezeiten des Arbeitssystems ergibt sich ein Konfliktpotenzial. Eine gute Planung ist hier in der Lage, die Arbeitssysteme auf eine maximale Leistung zu bringen, jedoch werden dafür Daten in Form von Rückmeldungen und Ist-Soll-Vergleichen benötigt. Das Fehlen dieser Daten ist auch die Ursache dafür, dass nicht die vollen Potenziale der Maschinen und Anlagen ausgeschöpft werden können. Rüstverluste, Dauer und Häufigkeit von Maschinenstillstände werden gar nicht oder nur teilweise erfasst und auch nicht ausgewertet. Die Folge daraus ist, dass Problemschwerpunkte nicht erkannt werden und datenbasierte Entscheidungen über geplante Verbesserungsmaßnahmen über Kosten-Nutzen-Gesichtspunkte getroffen werden.

Eine weitere Schwachstelle, die sich auch aus den logistischen Zielgrößen ableiten lässt, ist die Vorhaltung erhöhter Bestände. Hier ist es fatal, die Stammdaten und Systemparameter nicht auf

⁴⁹ Vgl. Nyhuis, P. et al. 2014, S. 80 f.; Vgl. Kletti, J./Schumacher, J. 2014, S. 39, 80.

⁵⁰ Vgl. Kellner, F. et al. 2020, S. 131 f.

dem aktuellen Stand zu haben, da sie einen ausgesprochen wichtigen Faktor im Einkauf und in der Wiederbeschaffung haben. So kann z.B. die Wiederbeschaffungszeit für jeden Artikel individuell in den Artikelstammdaten hinterlegt werden. In der Praxis werden diese Daten leider sehr grob behandelt und für alle Artikel oft derselbe Wert eingetragen.

Zur Optimierung der Durchlaufzeit kann eine bessere Feinplanung Schwächen auflösen. Informationen wie z.B. der exakte Auftragsfortschritt und der Maschinenstatus stehen für die Entscheidungsfindung nicht zeitnah zur Verfügung. Die langen Informationswege und teilweise falschen Stammdaten stören eine zeitnahe und effiziente Abarbeitung und ziehen den Gesamtprozess in die Länge. Eine leicht zu lösende Schwachstelle der DLZ sind prozessbedingte Wartezeiten, zu denen das Abkühlen oder Härten von Material gehört. Dies sind Prozesse, die keine aufwändige Bearbeitung, sondern nur Wartezeit in Anspruch nehmen. Das Problem ist, dass diese Zeiten nicht von der allgemeinen Bearbeitungszeit differenziert werden, woraus hohe Planungsvorteile gezogen werden könnten.

Parallel dazu entstehen während der Fertigung auch eine nicht zu vernachlässigende Menge an Ausschuss, welche ein Kostenfaktor darstellt. Dieses Qualitätsproblem hat ihren Ursprung in fehlerhafter Bearbeitung durch Personal und Maschinen, die eine Wartung benötigen. Zur Vermeidung von weitreichenden Folgen werden nach Erfahrungswerte die Menge an Ausschuss pauschal eingeplant, um die Bedarfe sicherzustellen.

In der zentralen Planung werden Kundentermine verhandelt und an den Kunden bestätigt, jedoch werden diese Kundentermine nicht realitätsnah kalkuliert, sodass die Termintreue leidet. Es werden oftmals zu geringe Vorgabezeiten für das Rüsten und die Bearbeitung sowie eine zu hohe Maschinenauslastung angenommen. Nicht deterministische technische Störungen an Maschinen werden sogar vernachlässigt oder falsch eingeschätzt. Die Folge daraus ist eine überplante Produktion, da die Realität mit den zu optimistischen Planungsprämissen nicht übereinstimmt. Der Prozess muss feiner dokumentiert und analysiert werden, damit erstens die Zeiten richtig betrachtet werden und zweitens Störungen besser eingeschätzt werden können.⁵¹

⁵¹ Vgl. Kletti, J./Schumacher, J. 2014, S. 39–58.

3 Data Science und Analytics

3.1 Einführung in die Data Science und Analytics

In der heutigen Betriebswirtschaft und somit auch in der Logistik sowie der Produktion ist es relevant, Daten zu erfassen und auszuwerten. Daten werden heute schon als Rohstoff zum Erhalt der Geschäftstätigkeit angesehen, mit dem das Wirtschaftsgut Wissen über Datenanalysen produziert wird. Dabei wird der Rohstoff der Daten schon als ein sehr wertvolles Wirtschaftsgut erkannt, das durch die Aufbereitung auch Einfluss auf den Gewinn der Unternehmung haben kann. Auch intralogistische Prozesse lassen sich mit datenbasierten Auswertungen der Vergangenheit optimieren, indem erkannt wird, durch wen oder was, wann, wo und wie der Prozess durchgeführt wird. Dieser wissensorientierte Ansatz dient dazu, dass relevante Informationen aus unterschiedlichsten Quellen gesammelt und transparent dargestellt werden und so zur Unterstützung von Managemententscheidungen genutzt werden können.⁵²

Auch wenn das Thema der Daten und der resultierenden Wissensschaffung in der heutigen Zeit eine hohe Präsenz hat, werden viele Fachwörter und Begriffe hervorgehoben, bei denen sich eine allgemeine Definition sich noch nicht etabliert hat, was eine Zuordnung und Abgrenzung von Teilbereichen sehr schwierig macht. Im Rahmen dieses Kapitels wird versucht, einen Überblick zu schaffen und Ordnung in die so oft erwähnten Schlagwörter der aktuellen wissenschaftlichen Diskussion zu bringen.

Zuerst ist der Begriff von Daten zu betrachten. Die Daten, welche letztendlich Informationen tragen, können in vielen unterschiedlichen Formen auftreten und dabei aus zahlreichen Quellen stammen, sodass es schwierig ist, größere Datenmengen von mehreren Petabytes einzuschätzen und gewissen Eigenschaften zuzuordnen. Die Daten können dabei in drei Datendimensionen differenziert werden, die in der Big Data Analytics wiederkehrend Anwendung finden.

- Volume:

Die Datenmenge wird auch als Volume bezeichnet. Dabei spielt es keine Rolle, ob die betrachteten Daten als Rohdaten vorliegen oder schon aufbereitet wurden. Hierbei muss auch das Management mit großen Datenmengen einbezogen werden. Eine wissenschaftliche Diskussion bezieht sich dabei auf die Wahl einer geeigneten

⁵² Vgl. Wagner, E. 2019, S. 8; Vgl. Plaue, M. 2021, S. 1.

Dateninfrastruktur, welche erstens die großen Datenmengen halten und gleichzeitig Rechnungen über High-Performance-Rechenzentren unterstützen kann

- Variety:

Wie bereits erwähnt, können Daten in unterschiedlichen Varianten vorliegen und dabei aus unterschiedlichen Quellen stammen. Diese Eigenschaft wird mit dem Begriff Variety umschrieben. In dieser Dimension liegt einer der größten Herausforderungen. Wissen aus einem Datenpool zu generieren, welcher keine Homogenität und Inkompatibilitäten aufweist. Dies erfordert die Verwendung von differenzierten Methoden. Oft werden dabei die Daten zuerst aufgespalten und die Ergebnisse zur einheitlichen und abschließenden Betrachtung wieder zusammengebracht. Ein weiterer verfolgter Ansatz ist es, eine Standardisierung in der internen Datenwirtschaft und -analyse durchzusetzen.

- Velocity:

Da das Volume für eine Datenanalyse schnell mehrere Petabytes überschreiten kann, ist es umso wichtiger die Datenmengen zügig zu analysieren und zur Verfügung zu stellen. Aus diesem Grund ist Velocity, also die Verarbeitungsgeschwindigkeit der Daten, nicht zu unterschätzen. Für unterschiedliche Datenarten gibt speziell programmierte Rechner, welche mit Verarbeitungszeiten von wenigen Stunden bis hin zu mehreren Tagen arbeiten. An diesem Punkt ist zu erkennen, welcher Aufwand betrieben werden muss, um Wissen aus unzähligen Datensätzen zu extrahieren.⁵³

Wurden die Daten erhoben und eingeschätzt, ist der nächste logische Schritt die Verarbeitung. Dabei werden mathematisch-statistische Methoden sowie verschiedene Formen von KI eingesetzt, um Prozesse zu optimieren. Um das verfügbare Potenzial zu nutzen, reichen die Kompetenzen im Bereich der Data Science und Data Analytics oft nicht aus.

Die Data Science oder im Deutschen Datenwissenschaften hat die zentrale Aufgabe, die Erfassung, Verarbeitung, Interpretation und Kommunikation von komplexen und unstrukturierten Daten und ihrer Umgebung, wozu insbesondere die zugehörigen Domänen zählen, mit dem Ziel der Gewinnung von belastbarem und nutzbringendem Wissen, das bei Entscheidungen unterstützend wirken kann, durchzuführen. Dafür werden in der Regel informationstechnische Mittel zur Hilfe genommen. Es werden die aktuellen technischen Möglichkeiten, wie umfassende Datenbestände und als übergreifendes Konstrukt die Methoden des maschinellen Lernens, verwendet. Es werden Kompetenzen aus den Bereichen Statistik,

⁵³ Vgl. Wagner, E. 2019, S. 8 f.; Vgl. Quix, C. 2021, S. 137 ff.

angewandte Informatik, Computing, Kommunikation, Management und soziale Aspekte benötigt. Darüber hinaus muss auch der Kontext einer geschäftlichen Motivation der Analysemethoden von Data Analytics bekannt sein. Die Arbeit lässt sich an einem Prozess erklären, welcher stufenweise von der inhaltlichen Fragestellung über die Datenvorverarbeitung, die eigentliche algorithmische Mustererkennung und Interpretation bis zur Modellimplementierung führt. Im Fokus des Data Scientist steht die Entwicklung von Entscheidungsmodellen, die wahlweise als interaktive Entscheidungsunterstützung oder als autonome Entscheidungsmaschine genutzt werden können, sodass diese in der Zukunft bei ähnlichen Fällen wiederverwendet werden.⁵⁴

Die Data Science lässt sich in vier Kernbereiche einteilen: Data Engineering, Data Prediction, Data Analytics und maschinelles Lernen. Data Engineering beschäftigt sich mit den möglichen Prozessen und Methoden der Datenspeicherung. Data Prediction versucht die Veränderungen erhobener Daten in der Zukunft auf Basis von generiertem Erfahrungswissen zu prognostizieren. Im Rahmen der Datenanalyse werden plausible und interpretierbare Muster erstellt, welche als Regelwerke die Entscheidungsmodelle bilden. Auch die Nutzung von maschinellem Lernen in Form von Data Mining ist Bestandteil der Data Science.⁵⁵

Die Data Analytics ist spezifischer und konzentrierter als die Data Science. Es wird eine Sicht auf komplexe Unternehmenssituationen ermöglicht, indem die Daten aller Prozesse betrachtet werden können. Im Bereich der Analyse werden Datensätze untersucht, um Trends zu erkennen, Diagramme zu entwickeln und Visualisierungen zu erstellen, mit denen Unternehmen Strategien, Aufbau und Abläufe optimieren können. Zur Aufbereitung der Rohdaten wird ein Prozess, bei dem die Komponenten eines bestimmten Datensatzes im Detail untersucht, herausgetrennt und die Teile einzeln und in ihrer Beziehung zueinander untersucht werden. Die Datenanalyse als solche ist eine Phase des Gesamtprozesses der Datenanalytik.⁵⁶

Im Bereich der Wirtschaftsinformatik stößt man auf zwei noch geschäftsspezifischere Begriffe, die Business Analytics und die Business Intelligence, die differenziert werden müssen. Während Data Analytics das Ziel hat Daten in einen analysierten und bereinigten Zustand zu bringen, nutzen Business Analytics und Business Intelligence diese Daten, um betriebswirtschaftliche Entscheidungen zu tätigen. Business Analytics kann als Sammlung der unterschiedlichen Methoden aus der deskriptiven, prädiktiven und präskriptiven Analytik

⁵⁴ Vgl. Nadikattu, R.R. 2020, S. 1 f.; Vgl. Plaue, M. 2021, S. 1; Vgl. Chamoni, P. 2021, S. XV–XVI; Vgl. Barton, T./Müller, C. 2021, S. 4 f.

⁵⁵ Vgl. Chamoni, P. 2021, S. XVI; Vgl. Barton, T./Müller, C. 2021, S. 4.

⁵⁶ Vgl. Kaufmann, U.H./Tan, A.B.C. 2021, S. 29 ff.

verstanden werden, welche Erkenntnisse für unternehmerische Entscheidungen aus den Daten der Data Analytics generieren. Die zukunftsorientierte Business Intelligence grenzt sich dadurch ab, dass die datengetriebene Analyse zur Planung und Prognoserechnung eingesetzt wird. Ein weiterer Begriff aus der Wirtschaftsinformatik ist die Advanced Analytics. Hierbei liegt der Fokus auf den Methoden des maschinellen Lernens und der Statistik, welche Ableitungen von Vorhersagemodellen mit Kausalzusammenhängen ermöglichen, die die Fähigkeiten der Business Intelligence überschreiten und somit eher auf die Stufe der Data Science zu setzen sind.⁵⁷ Zu sehen ist hier, dass sämtliche genannten Begriffe, die oft in der Literatur und in Fachartikeln verwendet werden, untereinander eine sehr enge Beziehung bis hin zu überlappenden Aufgabenhorizonten zueinander aufweisen, was es schwer macht, sie trennscharf voneinander zu unterscheiden. Fachzeitschriften und Fachliteraturen weisen noch Unschärfen in der Definition und synonymen Verwendung auf.

3.2 Die Transformation von Big Data zu Smart Data

Wichtige Bestandteile der bekannten Industrie 4.0 sind Big Data und die damit in Verbindung stehenden Big Data Analysis. Das Datenmanagement-System im Unternehmen hat sich zu einem komplexen Öko-System weiterentwickelt. Die unternehmensinternen Datenbanken sowie eine zunehmende Vernetzung zwischen Abteilungen und anderen Partnerunternehmen bieten einen Datenpool, der oft tief und undurchsichtig ist. Die Zunahme an Datenmengen, der Heterogenität der Daten und der Geschwindigkeit, in der Daten erzeugt werden, bilden die Charakteristik von Big Data ab. In diesem Zusammenhang werden besonders die Dimensionen von Volume, Variety und Velocity hervorgehoben. Die Daten liegen oft in unstrukturierter, komplexer Form vor und werden aus unterschiedlichsten Informationskanälen generiert. Bei Datenmengen, bei denen es nicht möglich ist, jeden Datensatz zur überprüfen existiert immer die Gefahr der Datenredundanz, der mangelnden Datenaktualität und der Beeinträchtigung des Datenschutzes von personalisierten Daten. In der Vergangenheit wurde von den Unternehmen erkannt, dass sich unter dieser dicken Schicht von scheinbar unbrauchbaren Datenmengen sich ein großer Wert verbirgt, sobald man in der Lage ist, diesen zu bergen und mithilfe der richtigen Methoden und Infrastrukturen Zusammenhänge zu erkennen und die Masse auf das wertvolle Wissen zu reduzieren.⁵⁸

⁵⁷ Vgl. Frazzetto, D. et al. 2019, S. 1; Vgl. Chamoni, P. 2021, S. XV.

⁵⁸ Vgl. Wagner, E. 2019, S. 8; Vgl. Nadikattu, R.R. 2020, S. 1; Vgl. Quix, C. 2021, S. 133.

Die Herausforderung bei diesem Prozess ist, dass die Menge an Datensätzen, die Big Data bietet, nicht mit traditionellen Datenverarbeitungssystemen wie relationalen Datenbanken verarbeitet werden können. Es werden Datenverarbeitungssysteme erforderlich, welche massive parallele Verarbeitung in einem Cluster mit vielen Rechenknoten nutzen. Beim Betrachten der zu verarbeitenden Menge an Daten kann nicht von Anfang an beurteilt werden, wie viele Ressourcen in Form von Prozessoren, Arbeitsspeicher sowie Festplattenspeicher aufgebracht werden müssen, um die gewünschten Ergebnisse zu erzielen. Dabei muss bei einer Rechnerarchitektur Flexibilität in Form von Skalierbarkeit gewährleistet sein. Diese Skalierbarkeit kann in Form von vertikaler und horizontaler Skalierung dargestellt werden. Einerseits können durch vertikale Skalierung einzelne Rechner mittels leistungsfähigerer Hardware erweitert werden, sodass eine höhere Performance erzielt werden kann. Andererseits können durch horizontaler Skalierung ganze Erweiterungen des Gesamtsystems durchgeführt werden. Dabei können dem Cluster neue Rechensysteme hinzugefügt werden.

Neben der anzustrebenden Leistungsstärke der Rechenzentren müssen auch Software Tools verwendet werden, die Big Data verarbeiten können. Ein geeignetes System bietet z.B. Apache Hadoop von Google. Hadoop war eines der ersten Systeme, dass die Anforderungen für Big Data Anwendungen erfüllte. Mit dem Hadoop Distributed File System können die Datenmengen auf mehreren Systemen dezentral gespeichert werden und trotzdem, dank dem Programmiermodell Map Reduce, parallel im Cluster verarbeitet und über die Ressourcenverwaltung YARN (Yet Another Resource Negotiator) verwaltet werden. Dies hat das Tor für weitere Big Data Anwendung geöffnet, die heute in vielen Bereichen präsent sind.

Das Ziel der Big Data Analysis ist es, die Transformation von unstrukturierter Big Data zur einer bereinigten, nutzbaren Smart Data zu reduzieren, mit der die gestellten Fragen beantwortet werden können. Smart Data entsteht, nachdem die Rohdaten gesammelt, geordnet und analysiert worden sind. Dafür wird der Prozess der Datenanalytik verwendet.⁵⁹



Abbildung 9: Datentransformationsprozess⁶⁰

⁵⁹ Vgl. Wagner, E. 2019, S. 8; Vgl. Zeisel, S. 2020, S. 3 f.; Vgl. Quix, C. 2021, S. 138.

⁶⁰ in Anlehnung an Kaufmann, U.H./Tan, A.B.C. 2021, Abb. 1.2.

Die Transformation wird über fünf Stufen vollzogen, die in der Abbildung 9 dargestellt werden. Der erste Schritt ist die Definition der geschäftsrelevanten Fragen. Wie o. g. werden Daten erst im Zusammenhang mit einer nutzbringenden Fragestellung wertvoll, sodass dieser erste Schritt nicht zu unterschätzen ist. In der Praxis kommt es oft vor, dass Datenanalysen nur durchgeführt werden, weil große Mengen von Daten zur Verfügung stehen. Jedoch weisen die resultierenden Erkenntnisse keinen großen Wert für die Unternehmung auf, sodass die Ressourcen verschwendet wurden. Hier ist es auch wichtig, die geschäftsbezogenen Themen klar zu identifizieren, da sie in einer quantifizierten Form vorliegen müssen. Es müssen messbare Indikatoren wie z.B. KPI verwendet werden.⁶¹

Der zweite Schritt befasst sich mit der Erfassung der Daten. Dafür werden Rohdatenquellen mittels eines sogenannten Datenkatalogs identifiziert. Der Datenkatalog bietet eine semantische Infrastruktur für die Rohdaten, sodass Metadaten, wie Datenbestände, Datenquellen und weitere Informationen den Datensätzen hinzugefügt werden. Das ermöglicht bei bestimmten Fragestellungen eine schnelle Findung der dazu relevanten Daten.⁶²

Um den Datenkatalog zu füllen, können eine Vielzahl von Möglichkeiten zur Datensammlung verwendet werden. Einerseits können Befragungen durchgeführt und die Ergebnisse in das System integriert werden, andererseits gibt es heute moderne Produktionsmaschinen die Daten, wie z.B. Last, Auslastung, Maschinenzustand, Umgebungsbedingungen usw. in Echtzeit bereitstellen können. Darüber hinaus kann bei älteren Maschinen auch eine entsprechende Sensorik kostengünstig nachgerüstet werden.⁶³ Trotz des Ziels, so viele Daten wie möglich zu sammeln, sollte auch auf dieser Stufe die Qualität der Daten sichergestellt werden. Faktoren, wie Datenverfügbarkeit, Datenqualität, valide Datenerhebung, geografische Restriktion bis hin zu rechtlichen Rahmenbedingungen können zu Problemen im späteren Prozessverlauf führen. Aus diesem Grund ist es ratsam die Schwächen so früh wie möglich zu identifizieren und auszuschalten.

Im Rahmen der Datenvorbereitung muss die Datenintegrität sichergestellt werden. In der Produktionsplanung gibt es regelmäßige Rückmeldeschleifen, welche die Planung kurzfristig beeinflussen können. Die dabei entstehenden Daten und deren Qualität haben einen engen Zusammenhang zur Qualität der Planung und den resultierenden Entscheidungen. Trotzdem ist es ein regelmäßiger Fall, dass fundamentale Daten Fehler enthalten, sodass die Entscheidungen

⁶¹ Vgl. ebenda, S. 7 ff.

⁶² Vgl. Wagner, E. 2019, S. 7 f.; Vgl. Deru, M. et al. 2021, S. 150.

⁶³ Vgl. Schöning, H./Dorchain, M. 2014, S. 545.

nicht die gewünschten Ergebnisse erzielen. In den meisten Situationen werden korrumpierte Datensätzen wertlos und verursachen zusätzliche Kosten, die vermieden werden könnten. Die Kosten von einer schlechten Datenintegrität und der daraus resultierenden falschen Entscheidungen werden auf 8% bis 12% des Umsatzes einer typischen Organisation geschätzt, dabei kann der Wert bei Unternehmen im Servicebereich auf bis zu 40% bis 60% ansteigen. Demnach sind fehlerhafte Datensätze nicht nur unbrauchbar, sondern können einen erheblichen Schaden an der finanziellen Struktur einer Unternehmung verursachen.

Um diese Kosten zu verhindern, werden die Datensätze innerhalb der Datenvorbereitung aufwendig aufbereitet. Um kaskadierenden Effekten entgegenzuwirken ist es jedoch sinnvoller, direkt beim Prozess der Datengenerierung einen Überprüfungsmechanismus zu implementieren. Ähnlich wie der Ansatz der Six Sigma des Qualitätsmanagements kann ein Prüfungsprozess in das System implementiert werden. Innerhalb eines Total Data Quality Managements kann der Kreisprozess mit den Schritten Definieren, Messen, Analysieren, Korrigieren und Kontrollieren direkt an der Quelle der Fehler zu einer Verbesserung der Datenintegrität führen. Dabei lässt sich die Datenintegrität in vier Dimensionen einteilen: Accuracy (Korrektheit), Timeliness (Aktualität), Consistency (Nachvollziehbarkeit), Completeness (Vollständigkeit). Sollte einer dieser Dimensionen verletzt werden, können Algorithmen Ergebnisse liefern, die nicht korrekt sind und trotzdem verarbeitet werden. Um die Datenintegrität zu erhalten, werden statistische Verfahren verwendet, um Anomalien zu erkennen und Korrelationen zur Fragestellung festzustellen.⁶⁴

Im Schritt der Datenanalyse werden unterschiedliche Verfahren verwendet, um brauchbare Ergebnisse in Verbindung zu Fragestellung zu erzielen. Der allgemeine Prozess der Datenanalyse bis hin zur Unterstützung bei Entscheidungsprozessen wird aus Abbildung 10 ersichtlich. Ein kleiner Einblick der gängigsten Analyseverfahren wird im Kapitel der Methodik dargestellt. Die Anzahl der möglichen Analyseverfahren ist sehr groß und wächst mit dem Fortschritt der Forschung stetig, sodass es unmöglich, ist alle Verfahren im Rahmen dieser Arbeit abzubilden. Wenn die Ergebnisse vorliegen und Smart Data in einer verständlichen und auch visualisierten Form dem Management vorliegt, können im letzten Schritt die Geschäftsentscheidungen getroffen werden.⁶⁵

⁶⁴ Vgl. Hazen, B.T. et al. 2014, S. 72 ff.; Vgl. Schuh, G. et al. 2017, S. 425 f.

⁶⁵ Vgl. Wagner, E. 2019, S. 7 f.; Vgl. Deru, M. et al. 2021, S. 150.

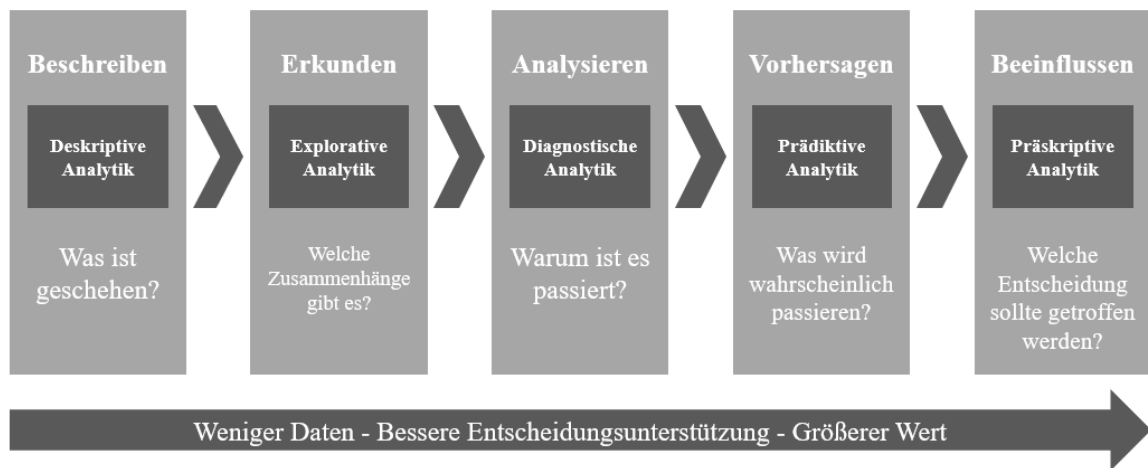


Abbildung 10: Data Analysis Prozess⁶⁶

3.3 Maschinelles Lernen

Um das Volume von Big Data analysieren zu können, werden Computer mit starker Rechenleistung genutzt. Einfache Analysen, welche über einen Algorithmus durchgeführt werden, können bei einer eindeutigen Datenlage in kürzester Zeit verarbeitet werden. Jedoch ist die Datenlage in einem komplexen System nicht leicht zu durchdringen. Die Datensätze, welche im Produktionssystem gesammelt werden, beinhalten übergreifende Interdependenzen und zahlreiche Merkmale, welche einen Algorithmus mit größtem Programmieraufwand benötigt. Aus diesem Grund werden in solchen Situationen lernende Maschinen angewendet. Maschinelles Lernen oder auch Machine Learning wird über einen Algorithmus ermöglicht, der in der Lage ist, Analysen so lange durchzuführen und sich selbst anzupassen, bis als Ergebnis eine nahezu perfekte und fehlerfreie Antwort herauskommt. Vor Allem in der Big Data Analysis spielt maschinelles Lernen eine große Rolle, weil so aus einer unscheinbaren Datenmenge Zusammenhänge und Strukturen erkannt werden können.⁶⁷

Die wichtigsten Verfahren sind die künstlichen neuronalen Netzwerke, welche auf der Funktion von biologischen Nervensystemen beruhen. In der Abbildung 11 ist ein künstliches neuronales Netzwerk dargestellt. Als Neuronen dienen Kreise und für Synapsen werden die Pfeile verwendet.

⁶⁶ in Anlehnung an Shao, G. et al. 2014, Abb. 1.

⁶⁷ Vgl. Frochte, J. 2020, S. 18 f.




Abbildung 11: Künstliches Neuronales Netzwerk⁶⁸




Abbildung 12: Aktivierungsfunktion (Sigmoidfunktion)⁶⁹

Auf Ebene der Eingabe werden die Daten in mehrere Einzelteile (x_1 , x_2) aufgespalten, z.B. könnte ein Bild in die einzelnen Pixel und Farbausprägung aufgeteilt werden. Wenn die Information über die Synapsen an ein Neuron weitergereicht wird, aktiviert sich ein Prüfungsprozess auf Basis einer Aktivierungsfunktion (f_{11} , f_{12} , ..., f_{22}), wie z.B. die Sigmoidfunktion $sig(t)$ in Abbildung 12. Die Funktion dient dazu, das Neuron erst dann zu aktivieren und die Information weiterzuleiten, wenn die Informationen eine Reizschwelle von $t=0$ überschritten hat.

Dieser Prüfungsprozess wird über die Ebenen und anderen Neuronen wiederholt. Während des ersten Durchganges ist die Ausgabe y als Ergebnis in der Regel fehlerhaft. Dieser Fehler wird

⁶⁸ in Anlehnung an Plaue, M. 2021, Abb. 6.8.

⁶⁹ in Anlehnung an ebenda, Abb. 6.9.

dem System rückgemeldet, worauf alle Aktivierungsfunktionen angepasst werden. Dieser Anpassungsprozess wird pro Durchgang so oft wiederholt, bis ein korrektes Ergebnis als Ausgabe erzielt wird. Darüber hinaus wird die Ergebnisfindung auch immer weiter optimiert und entwickelt, da die ausschlaggebenden Merkmale für das Ergebnis vom neuronalen Netz erkannt und mittels der Aktivierungsfunktion hervorgehoben werden. Allgemein ist es das Ziel die Aktivierungsfunktionen so auf die Fragestellung zu trainieren und kontinuierlich zu verbessern, dass die Ergebnisse immer richtig sind. Je mehr Ebenen ($l=1$, $l=2$) hinzugefügt werden, umso komplexer und vielschichtiger können Fragestellung und Datensätze sein. Bei einem künstlichen neuronalen Netz mit vielen Neuronenschichten ist auch die Rede vom Deep Learning.⁷⁰

Des Weiteren wird zwischen zwei Varianten unterschieden: überwachtes maschinelles Lernen und unüberwachtes maschinelles Lernen. Das überwachte maschinelle Lernen benötigt einen Lehrer, der einem zeigt, was richtig und was falsch ist. Diese Rolle wird vom sog. Trainingsdatensatz übernommen. Der Trainingsdatensatz beinhaltet markierte Daten, die eine trainingsausreichende Reihe von Fällen und dazugehörige richtige Ergebnisse beinhalten. Anhand dieses Trainings kann das neuronale Netz seine eigenen relevanten Merkmale aufstellen und ein globales Modell definieren, welches für neue Fälle immer wieder verwendet werden kann. Dabei ist die Anwendung für Aufgaben wie Klassifikationen, bei denen eine diskrete Zielmenge vorliegt und Regressionsverfahren bei metrischen Zielmengen ideal.⁷¹ Diese trainingsintensive Herangehensweise wird auch als Eager Learner bezeichnet. Sollte das aufwändige Training zu viel Zeit in Anspruch nehmen, kann auch ein Lazy Learner verwendet werden, welcher erst bei der Entscheidung ein lokales Modell aus seinen Erfahrungen konstruiert und nicht in der Lage ist, auf ein vordefiniertes globales Modell zuzugreifen.⁷²

Beim unüberwachten maschinellen Lernen ist das Ziel aus einer Menge von unmarkierten Daten versteckte Strukturen und Gruppen ausfindig zu machen. Hierbei liegen keine Zielgrößen oder Klassenlabel vor. In der Regel werden zwei Arten dieses Verfahrens verwendet. Erstens dient das Verfahren zur Clusteranalyse. Dabei wird versucht, die Datensätze in ähnlichen Informationsobjekte einzuteilen. Somit ist die Clusteranalyse mit der Klassifikation zu vergleichen, jedoch liegt der Unterschied darin, dass es keine Vorgabe für die Klassifikation gibt und der Algorithmus die Merkmale selbst definiert, sodass verborgene Korrelationen und Zusammenhänge zwischen Datensätze gefunden werden können. Zweitens werden

⁷⁰ Vgl. Frochte, J. 2020, S. 20 ff.; Vgl. Plaue, M. 2021, S. 232 ff.

⁷¹ Vgl. Plaue, M. 2021, S. 190.

⁷² Vgl. Frochte, J. 2020, S. 23.

Dimensionsreduktionen durchgeführt. Die Dimensionen können als die unterschiedlichen Merkmale oder Ausprägungen der Datensätze angesehen werden. Bei einer spezifischen Fragestellung kann der unüberwachte Computer ohne Einschränkungen festlegen, welche der Merkmale relevant sind und welche im Sinne der Fragestellung ignoriert werden können.⁷³

3.4 Methoden der Datenanalytik

3.4.1 Deskriptive Analytik

Die grundlegendste Art der Datenanalyse ist die der deskriptiven (beschreibenden) Analyse, hier werden die gesammelten Rohdaten mit statistischen Methoden ausgewertet, sodass der erste Wert aus den Informationen generiert wird. Es werden alle Verfahren verwendet, mit denen sich durch die Beschreibung von Daten einer Grundgesamtheit von Informationen gewinnen lassen. Die Ergebnisse der Verfahren werden in Form von Grafiken, Tabellen und Berechnungen von deskriptiven Kennzahlen bzw. Parametern dargestellt. Dabei ist es ein besonderer Teil der Charakteristik der deskriptiven Analyse, die Rohdaten zusammenfassend und reduziert für den Interessenten darzustellen. Des Weiteren werden die Daten mit einer Erwartung in Bezug auf Theorien und Erfahrungen betrachtet, sodass die Verfahren zielorientiert gewählt werden, um Ergebnisse für bestimmte Fragestellungen zu erhalten.⁷⁴

In diesem Bereich der Statistik werden Daten von unterschiedlichster Skalierung genutzt. Nominale und ordinale Skalierungen, bei denen qualitative Ausprägungen verwendet werden, benötigen zur Computerintegration eine Art der Kodierung, sodass die qualitativen Werte quantifiziert werden. Im Bereich der metrischen oder kardinalen Skalierung liegen die Daten schon in quantifizierter Form vor, sodass ein Großteil der Verfahren direkt angewandt werden kann.⁷⁵

In der deskriptiven Datenanalyse wird zwischen der Anzahl der betrachteten Variablen differenziert. Bei den Verfahren der fundamentalen univariaten Analyse werden nur einzelne Variablen der Datensätze betrachtet, sodass nur Ausprägungen des einen Wertes Wissen schaffen können. Dabei werden statistische Kennzahlen wie z.B. geometrische Mittel, harmonische Mittel und Median berechnet. Zusätzlich werden die Werte grafisch visualisiert, wobei es wichtig ist, Grafiken überschaubar zu gestalten, indem metrische Werte mittels einer

⁷³ Vgl. ebenda, S. 24 f.; Vgl. Plaue, M. 2021, S. 255.

⁷⁴ Vgl. Cleff, T. 2011, S. 4 f.

⁷⁵ Vgl. ebenda, S. 20.

Klassierung in Abschnitte eingeteilt werden. Auch die Analyse von Streuungsparametern kann wertvoll sein. Mittels Standardabweichungen, Variationskoeffizienten sowie Konzentrationsraten können Schwankungen, Streuungen und Konzentrationen des Wertes ermittelt werden.⁷⁶

Werden zwei Variablen betrachtet wird über bivariate Analysen gesprochen, bei mehreren Variablen ist die Rede von multivariaten Analysen. Diese Betrachtungen liefern wertvolle Informationen über Zusammenhänge zwischen Variablen. Bei zwei Variablen kann ein grafischer Zusammenhang in Streudiagrammen dargestellt werden, um das Verhältnis verständlich zu betrachten. Um Korrelationen zu berechnen, wird der Korrelationskoeffizient nach Bravais-Pearce sowie die Rangkorrelation nach Spearman verwendet.⁷⁷

Eines der wichtigsten statistischen Analyseverfahren ist die der Regressionsanalyse. Dabei wird dieses Verfahren bei bivariaten sowie einer multivariaten Analysen verwendet. Demnach werden zwei oder mehrere Variablen betrachtet, denen eine Korrelationen und eine kausale Richtung des Zusammenhangs unterstellt wird. Dabei unterscheidet man abhängige und unabhängige Variablen, sodass analysiert werden kann, wie sich die abhängige Variable bei der Veränderung der unabhängigen Variable verhält. Im späteren Verlauf der prädiktiven Analyse wird dieser Zusammenhang zur Prognose verwendet.⁷⁸

3.4.2 Explorative Analytik

Eine Weiterentwicklung der deskriptiven Analyse ist die explorative (erkundende) Analyse. Das Ziel der explorativen Analyse ist es auch, eine beschreibende Erkenntnis aus dem Ist-Zustand zu realisieren. Im Gegensatz zur deskriptiven Analyse, die immer zielorientiert Daten für angestrebte Ergebnisse begutachtet, hat die explorative Analyse, wie der Name verrät, einen erkundungsfreudigeren Charakter und verfolgt kein direktes Ziel. Es werden mithilfe von unüberwachtem maschinellen Lernen Daten untersucht und über die nötigen Analyseverfahren Strukturen und Korrelationen aufgedeckt, die nicht bekannt waren. Mit diesen neuen Erkenntnissen können Interdependenzen und Korrelationen von komplexen Systemen erkannt werden. Werden explorative Datenanalysen stark ausgeprägt verfolgt, so wird auch von Data Mining gesprochen. Der Begriff Data Mining ist im Bereich der Datenanalyse sehr präsent und beschreibt einen Prozess der Aufklärung von interessanten Mustern, Regelmäßigkeiten,

⁷⁶ Vgl. ebenda, S. 39 ff.

⁷⁷ Vgl. ebenda, S. 103 ff.

⁷⁸ Vgl. ebenda, S. 147 ff.

Gesetzmäßigkeiten sowie verborgenen Zusammenhängen in großen Datenmengen. Unter Einbeziehung von Experten, die den Kontext der Datenanalyse kennen, können wertvolle Erkenntnisse über ein komplexes System geschöpft werden.⁷⁹

Zur explorativen Analyse wird unüberwachtes maschinelles Lernen benutzt, da das Wissen selbst dem Lehrer nicht bekannt ist, sodass der Algorithmus seine eigenen Regeln aufstellen muss. Aus diesem Grund werden neben den o.g. klassischen deskriptiven Analyseverfahren, die mithilfe von Grafen und Kennzahlen Einsicht in die Datenlage bieten, Dimensionsreduktion und Clusteranalysen verwendet.

Das Verfahren der Dimensionsreduktion wird in der Regel über eine sog. Hauptkomponentenanalyse durchgeführt. Deren Aufgabe ist es, hochdimensionale Daten, die oft als Big Data vorliegen und sehr rechenintensiv sind, auf wenige relevante Dimensionen zu reduzieren, sodass auch der Ressourcenaufwand minimiert werden kann und die wesentlichen Informationen erhalten bleiben. Um das zu ermöglichen, werden erstens mehrere der relevanten Daten miteinander verknüpft und in nur einer Dimension vereint. Dies geschieht mittels Linearkombination, sodass mehrere Merkmale in einer Dimension zu sog. Hauptkomponenten zusammengefasst werden. Aus diesen Hauptkomponenten werden diejenigen mit der größten Varianz ausgewählt, sodass nur die Hauptkomponenten vorliegen, die wichtige Daten beinhalten aber wenig Korrelation zueinander haben.⁸⁰

Das Verfahren der Clusteranalyse versucht Objekte auf Basis von Merkmalen in feste Cluster einzuordnen. Dabei wird, wie bei der Dimensionsreduktion, unüberwachtes maschinelles Lernen verwendet, sodass der Algorithmus keine Vorgaben von einem Lehrer erhält und somit eigenständig die wichtigen Merkmale definieren muss. Die klassischen Clusterverfahren werden in zwei Arten eingeteilt: das hierarchische Verfahren und das partitionierende Verfahren.

Beim hierarchischen Verfahren kann einerseits die Menge der Objekte in einen Hauptcluster organisiert werden, der in einer Schleife immer weiter aufgeteilt wird (divisives Verfahren), andererseits bildet jedes Objekt seinen eigenen Cluster, welche danach in Clustergruppen zusammengefasst werden (Agglomerates Verfahren). Um zu erkennen, dass Objekte kompatibel sind und ähnliche Merkmale aufweisen, wird die Distanz der beiden Objekte grafisch ermittelt. Der Idealfall gestaltet sich hier so, dass dank vorangehender Datenreduktion die Merkmale auf zwei Dimensionen vereint werden, sodass eine zweidimensionale Grafik

⁷⁹ Vgl. Plaue, M. 2021, S. 3.

⁸⁰ Vgl. von der Hude, M. 2020, S. 83 ff.

ausreicht und der Rechenaufwand niedrig bleibt. In der Abbildung 13 ist eine beispielhafte Darstellung des Clusterverfahrens dargestellt. Bei der Distanzmessung von Objekten wird zwischen einer Betrachtung der kürzesten oder der weitesten Abstände unterschieden. Bei der Distanzmessung von gebündelten Clustern (C_1, C_1, C_1) kann darüber hinaus eine Betrachtung der durchschnittlichen Distanzen zwischen den Clusterobjekten oder der Distanz zwischen Clustermittelpunkten verwendet werden.

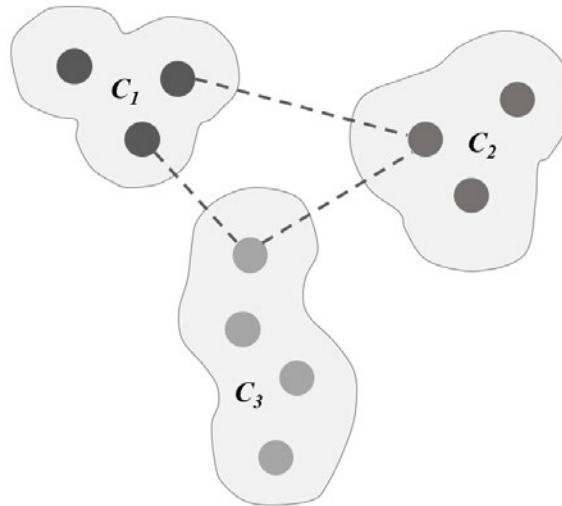


Abbildung 13: Clusteranalyse⁸¹

Beim partitionierenden Verfahren wird eine feste Clusteranzahl vorgegeben, in die alle Objekte nach Zufall zugeordnet werden. Danach werden die Objekte in einer Schleife so lange verschoben, bis sich optimale homogene Cluster gebildet haben. Mit der Within-Cluster-Sums-of-Square-Methode kann die optimale Anzahl ermittelt werden. Dafür wird die Summe der quadratischen Abweichung des ersten Clusterzentrums berechnet. Danach wird die entsprechend ermittelte Summe eines neuen Clusterzentrums addiert. Dies wird so lange fortgeführt, bis die Addition eines zusätzlichen Clusters keine signifikante Abweichung mehr aufweist und so die optimale Anzahl gefunden wurde. Mit der optimalen Clusteranzahl kann das K-Means Verfahren verwendet werden. Die Durchführung beginnt mit der zufälligen Setzung der Clusterzentren und der Zuordnung der Objekte zum nächstliegenden Clusterzentrum. Daraufhin wird mit den zugeordneten Objekten der geografische Mittelwert gebildet und das Clusterzentrum dorthin verschoben. Danach beginnt wieder die Objektzuordnung und die Schleife wird bis zur optimalen Verteilung fortgesetzt.⁸²

⁸¹ in Anlehnung an ebenda, Abb. 5.2.

⁸² Vgl. ebenda, S. 49 ff.

3.4.3 Diagnostische Analytik

Die nächste Stufe des Datenanalyseprozesses ist die diagnostische (analysierende) Analytik. Während die explorative und deskriptive Analytik versuchte, den Sachverhalt und die Zusammenhänge transparent darzustellen, verfolgt die diagnostische Analytik dagegen das Ziel, die Hintergründe zu verstehen, also warum etwas passiert bzw. wie es zu dem beschriebenen Sachverhalt kommen konnte. Darüber hinaus zeigt sie auf, welche Faktoren zu einer Performance geführt haben und wie groß der Einfluss dieser Faktoren auf die Zielgröße ist. Indem Sensitivanalysen durchgeführt werden, können mittels Simulationen, die das reale System nachahmen, die Vorgänge und Verkettungen nachvollzogen werden, die zum Endergebnis geführt haben.

Das erstellte Simulationsmodell muss dabei eine verifizierte und validierte Darstellung des Systems gewährleisten können. Um nachvollziehen zu können, warum etwas z.B. ein Maschinenausfall entstanden ist, müssen Sensitivanalysen durchgeführt werden. Die Sensitivanalysen überprüfen, wie sensitiv eine Zielgröße auf einen bestimmten Input reagiert. Somit können viele Szenarien mit unterschiedlichen Inputs im Simulationsmodell berechnet werden, bis ein Muster zu erkennen ist, das verrät, welche Faktoren relevant für den Maschinenausfall sein könnten.⁸³

3.4.4 Prädiktive Analytik

In der prädiktiven Analytik wird der Blick in die Zukunft gerichtet. Es werden Vorhersagen mit Analyseverfahren getätigt, welche den Verlauf einer Variable mit Hilfe einer oder mehrerer anderer Variablen aufzeigen. Die Variablen, welche somit Einfluss auf die Vorhersage haben, werden Einflussgrößen oder Prädiktoren genannt. Des Weiteren wird die Variable der angestrebten Vorhersage als Zielgröße bezeichnet. Da in dieser Art der Analyse überwacht maschinelles Lernen verwendet wird, ist es nötig einen Trainingsdatensatz für die Zielgrößenermittlung zu erstellen.

In diesem Abschnitt werden zwei präzise Prognoseverfahren näher erläutert. In der Regel werden Regressionsanalysen und Klassifikation für Prognosen verwendet.⁸⁴ Das Klassifikationsverfahren des nächster-Nachbar-Klassifikators versucht, ähnlich wie bei der

⁸³ Vgl. Shao, G. et al. 2014, S. 2195.

⁸⁴ Vgl. von der Hude, M. 2020, S. 95.

Clusteranalyse, über grafische Positionierung der Datenobjekte den nahe liegenden Nachbarn ausfindig zu machen und einer Klasse hinzuzufügen. Idealerweise werden auch hier die Datensätze auf zwei Dimensionen reduziert. Im Gegensatz zur Clusteranalyse muss der Algorithmus geschult werden und bearbeitet einen Trainingsdatensatz. Dabei wird das Prinzip des Lazy Learners angewendet, bei dem keine Klassifikationsvorschrift vordefiniert wird, sondern nur die Daten und Ergebnisse gespeichert werden. Bei der Zuordnung eines möglichen zukünftigen Objektes zu einer Klasse, werden die Daten begutachtet und das Objekt einer Klasse hinzugefügt, indem die gelabelten Objekte mit ähnlichen Merkmalsvektoren ausgestattet sind. Eine Weiterentwicklung des nächster-Nachbar-Klassifikators ist der des k-nächsten-Nachbarn-Klassifikators, bei dem nicht nur ein Nachbar pro Durchgang gesucht wird, sondern gleich eine Anzahl k von Nachbarn, daraus folgt, dass diese Weiterentwicklung wesentlich besser mit überlappenden Klassengrenzen arbeiten kann.⁸⁵

Die Regressionsanalyse wird wie o.g. dazu verwendet, um den Einfluss einer unabhängigen Variable auf einer abhängigen Variable festzustellen. Das daraus resultierende Verhalten lässt sich nutzen, um Prognosen der abhängigen Variable aufzustellen. Die einfachste Form der Regressionsanalyse ist die der linearen Regressionsanalyse. In der Abbildung 14 wird eine Regression zwischen der abhängigen Variable y und der unabhängigen Variable x erstellt. Die Objekte, welche als Punkte dargestellt werden, sind gesammelte Datensätze, die das Verhältnis der beiden Variablen in der Vergangenheit abgebildet haben.

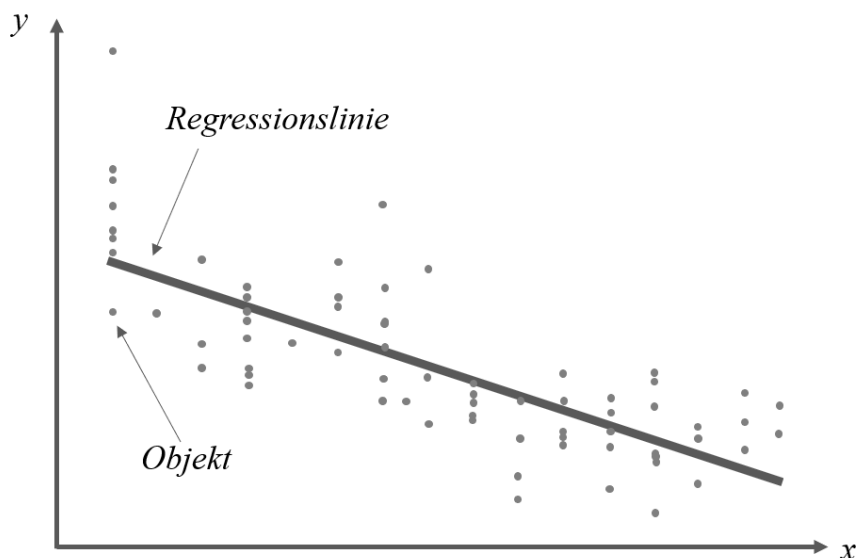


Abbildung 14: lineare Regressionsanalyse⁸⁶

⁸⁵ Vgl. Runkler, T.A. 2015, S. 100 f.

⁸⁶ in Anlehnung an Larose, D.T. 2006, Abb. 2.1.

Die lineare Regressionslinie wird so angesetzt, dass alle Punkte die geringste Distanz zur Linie aufweisen. Mit der daraus resultierenden Geradengleichung kann das Verhältnis zwischen x und y abgebildet werden, sodass man in der Lage ist bei einer Veränderung der unabhängigen Variable die abhängige Variable zu prognostizieren. Sollten zwei oder mehrere unabhängige Variablen Einfluss auf die abhängige Variable haben, wird die Analyse in Form einer multiplen linearen Regressionsanalyse durchgeführt. Dabei wird keine zwei-dimensionale Gerade betrachtet, sondern eine zwei- bis mehrdimensionale Ebenen, die wiederum einen höheren Rechenaufwand mit sich bringt. Sollten die Positionen der Objekte keinen linearen Zusammenhang aufweisen, werden polynomiale Regressionen verwendet, die es erlauben z.B. quadratische Zusammenhänge als Regressionslinie darzustellen.⁸⁷

3.4.5 Präskriptive Analytik

Die präskriptive Analyse ist die letzte Phase des klassischen Data Analysis Prozesses. Im Gegensatz zur deskriptiven und prädiktiven Analytik, die Daten der Vergangenheit und Zukunft aufbereiten, dient die präskriptive Analytik dazu, den Entscheidungsprozess auf Basis der geschaffenen Datengrundlage der vorhergehenden Phasen zu unterstützen. Die Aufgabe ist es, Verfahren zu entwickeln, um die besten Entscheidungsalternativen innerhalb eines komplexen Systems mit zahlreichen Objekten, Voraussetzungen und Interdependenzen zu finden und zu bewerten. Mithilfe von maschinellem Lernen und den Daten aus der prädiktiven und deskriptiven Analysen können iterative numerische Optimierungsprozesse durchgeführt werden.⁸⁸

Unter den gängigen Analyseverfahren sind allgemeine stochastische Methoden, Entscheidungsbäume und Simulationen in Form der Monte-Carlo-Simulationen zu finden.⁸⁹ Entscheidungsbäume sind eine tradierte Methode, die in Kombination mit dem heutigen überwachten maschinellen Lernens einen wertvollen Beitrag für die präskriptive Analyse bietet. In der Abbildung 15a ist ein beispielhafter Entscheidungsbaum aufgezeigt. Nach dem dafür gängigen ID3-Algorithmus (Iterative Dichotomiser 3) wird bei dem obersten Knotenpunkt die Entscheidung mit dem höchsten Information-Gain vorgezogen. Dies bedeutet, dass die erste Entscheidung den größten Einfluss auf das Ergebnis hat, da in Abbildung 15b erkannt werden

⁸⁷ Vgl. ebenda, S. 33 f., 93; Vgl. von der Hude, M. 2020, S. 107 f., 113, 114 f.

⁸⁸ Vgl. Frazzetto, D. et al. 2019, S. 575 f., 579.

⁸⁹ Vgl. Wrona, T./Reinecke, P. 2019, S. 448.

kann, dass die Trennlinie der ersten Entscheidung den größten Bereich aufteilt. Bei der Erstellung eines Entscheidungsbaumes über maschinelles Lernen, wird jeder Pfad über Klassifikation zugeordnet, bis keine Variablen zum Aufteilen mehr verfügbar sind. Ist die Erstellung mit allen relevanten Variablen durchgeführt, tendieren Entscheidungsbäume oft dazu lang und komplex zu werden, was einen höheren Rechenaufwand fordert. Letztendlich kann mit der entsprechenden Zielsetzung und Entscheidungsbäumen eine optimale Auswahl getroffen werden.⁹⁰

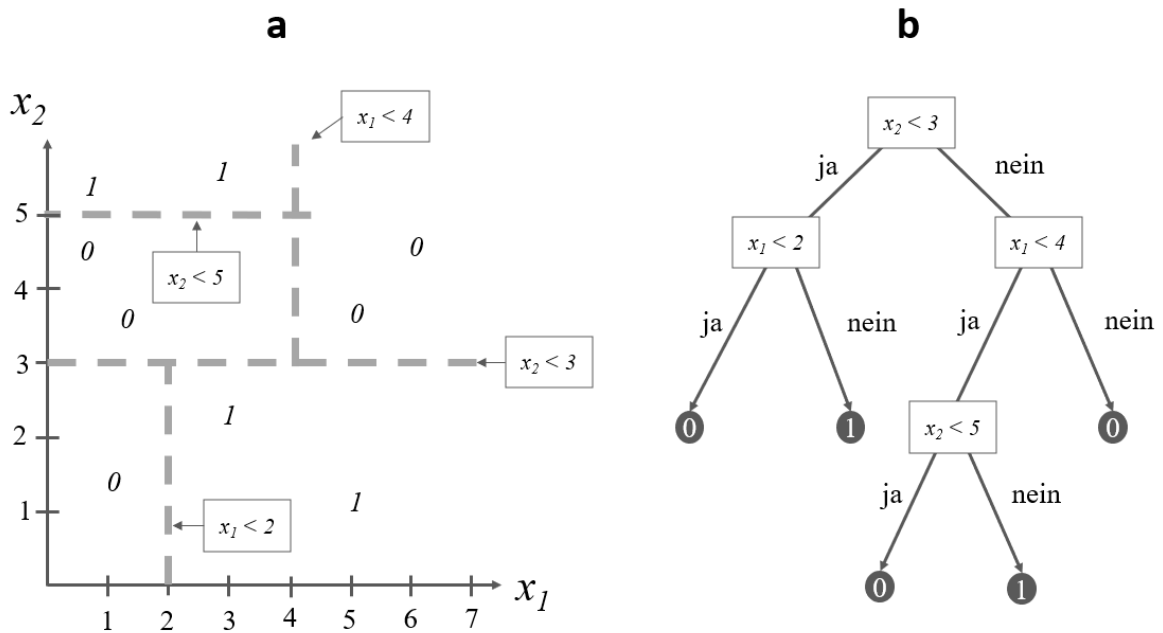


Abbildung 15: Entscheidungsbaum⁹¹

Die Nutzung von Simulationen, wie die Monte-Carlo-Simulationen, können einen Einblick in die Folgen von gewissen Entscheidungen bringen, sodass Informationen über Ergebnisse schon vor der eigentlichen Entscheidung zur Verfügung stehen. Die Monte-Carlo-Simulationen basieren dabei auf wiederholten zufälligen Stichproben. Die Methodik lässt sich in vier typischen Schritten aufteilen. Zuerst muss ein statisches, deterministisches Modell generiert werden, das auf realen Situationen basiert. Zur Erstellung werden die relevantesten Variablen identifiziert und mit anderen Variablen in mathematische Korrelationen gestellt, sodass als Ergebnis des Modells der gewünschte Output entstehen kann. Danach müssen im zweiten Schritt die Risikokomponenten berücksichtigt werden, dabei muss die Verteilung der Inputvariablen und der Risikokomponenten mit stochastischen Methoden analysiert werden. Sollte die Verteilung erkannt sein, können im letzten Schritt nach der Verteilung zufällig Inputvariablen

⁹⁰ Vgl. Knuth, T. 2021, S. 364–367.

⁹¹ in Anlehnung an ebenda, Abb. 4.

generiert werden und dem deterministischen Modell als Input bereitgestellt werden. Als Ergebnis liegen viele mögliche Outputvariablen vor. Die möglichen Entscheidungsfolgen werden analysiert und mit dem Ziel verglichen, sodass eine optimale zielorientierte Alternative gefunden werden kann.⁹²

Damit die Entscheidungen zur Optimierung führen und die präskriptive Analyse erfolgreich ist, spielen fünf Faktoren eine besondere Rolle. Erstens sollten neben den strukturierten Daten der prädiktiven und deskriptiven Analysen auch unstrukturierte Daten hinzugezogen werden, die möglicherweise noch wertvolle Details für spezielle Entscheidungen beinhalten. Solch ein gemischter Datensatz wird auch als Hybrid Data bezeichnet und findet immer mehr Anwendung in der Praxis. Zweitens muss die prädiktive und präskriptive Analytik eng zusammenarbeiten und im stetigen Austausch stehen. Sollten beide Bereiche Ergebnisse aus den eigenen Systemen generieren, kann dies zu Überschneidungsproblemen führen. Hinzu kommt, dass schlechte Entscheidungsergebnisse als Rückkopplungsinformation der prädiktiven Analytik zur Optimierung der Algorithmen übersendet werden müssen. Drittens müssen neben den Methoden der präskriptiven Analytik auch die bereits verwendeten Erkenntnisse und ähnlich angesetzte Modelle aus der Operations Research einbezogen werden. Darüber hinaus müssen auch die vordefinierten Geschäftsregeln, die teilweise elementare technische Sachverhalte beschreiben, integriert werden. Viertens dürfen die verwendeten Algorithmen keine starre Struktur aufweisen. In einer Welt von steigenden Datenmengen (Volume, Velocity und Variety) ist es wichtig, auf dynamische Veränderungen von Rahmenbedingungen reagieren zu können. Deshalb müssen die Algorithmen über einen Mechanismus der automatischen Rekalibrierung verfügen, sodass bestehende Algorithmen angepasst werden oder sogar Neue entstehen. Letztens müssen die Ergebnisse stets über einen Feedbackmechanismus überprüft werden. Hier muss auch einbezogen werden, dass ein Hauptverantwortlicher eine abweichende Entscheidung trifft und sich über die präskriptive Analyse stellt. In diesem Fall muss untersucht werden, ob einerseits die Entscheidung besser war, sodass daraufhin die Parameter des Algorithmus angepasst werden. Andererseits kann überprüft werden, ob die Entscheidung der Analyse zu einem besseren Ergebnis geführt hätte. Werden diese fünf Faktoren beachtet sollte es nicht an einer erfolgreichen präskriptiven Analyse scheitern.⁹³

⁹² Vgl. Raychaudhuri, S. 2008, Abs. 3.

⁹³ Vgl. Basu, A. 2013, S. 1 ff.

4 Bewertung der Data Science Methoden anhand der Planungsqualität einer Produktionsplanung

4.1 Matrix zur Untersuchung

Zur Untersuchung der Anwendungsmöglichkeiten von Data Science und Analytics, um die Planungsqualität zu verbessern, wird betrachtet in welchen Kernaufgaben der PPS des Aachener Modells die Data Analytics Anwendung finden könnten. Als grafische Übersicht werden in der Abbildung 16 die Zusammenhänge zwischen der Datenanalytik und den Kernaufgaben sowie den Teilaufgaben dargestellt. Dabei wird zwischen leeren Kreisen und vollen Kreisen differenziert, die eine starke oder eine schwache Ausprägung des Nutzungspotenzials gegenüber der Planungsqualität aufzeigen sollen. Im Verlauf der Bewertungen werden die Kernaufgaben in eigenen Kapitel untergliedert, indem die Bereiche und möglichen Potentiale bewertet und untersucht werden.

Kernaufgaben	Teilaufgaben	Deskriptive Analytik	Explorative Analytik	Diagnostische Analytik	Prädiktive Analytik	Präskriptive Analytik
Produktionsprogrammplanung	Absatzplanung	○	○		●	
	Primärbedarfs- und Ressourcengroßplanung	○		○	●	
Produktionsbedarfsplanung	Sekundärbedarfsermittlung	○		○	●	
	Beschaffungsartzuordnung					●
	Durchlaufterminierung		●			
	Kapazitätsabstimmung	○	○	○		
Eigenfertigungsplanung	Losgrößenrechnung			●		
	Feinteminierung	○		○	●	
	Ressourcenfeinplanung	○	○	○		
	Reihenfolgeplanung			●		
Fremdbezugsplanung	Bestellrechnung	○		○	●	
	Angeboteinholung/-bewertung	○		○	●	
	Lieferantenauswahl					●

Abbildung 16: Matrix zu Untersuchung⁹⁴

⁹⁴ Eigene Darstellung

4.2 Diskussion der Kernaufgaben der Produktionsplanung

4.2.1 Produktionsprogrammplanung

Einer der schwierigsten Teilaufgaben der PPS ist die Absatzplanung. Im heutigen Käufermarkt ist es schwierig den möglichen Absatz und dessen Schwankungen zu prognostizieren, damit die Produktion nicht zu viele oder zu wenige Kapazitäten einplant und eine kostenoptimale Absatzmenge anstrebt, welche die Termintreue sichert und gleichzeitig nicht in zu hohen Beständen resultiert. Eine effiziente Kapazitätsplanung benötigt deshalb eine robuste Absatzplanung. Vor Allem durch den Sukzessivplanungsansatz muss sichergestellt werden, dass die Daten der ersten Planungsebene von höchster Qualität sind, damit die Ergebnisse der folgenden Planungsschritte nicht negativ beeinflusst werden. Um die Präzision der Absatzprognosen zu gewährleisten, können Data Analytics durchgeführt werden. Die wichtigsten Informationen zur Aufstellung einer robusten Prognoseplanung liefern die Kunden und die vergangenen Absatzzahlen. Aus diesem Grund werden über die Datenerfassung z.B. externe Daten wie Kundensegmente aller Distributionskanäle, Entwicklung verwandter Branchen, regelmäßige Events (Feiertage) und Vergangenheitsdaten aus interner Quelle gesammelt. Dabei können auch Echtzeitdaten zwischen Handelspartnern und Supply-Chain-Akteuren ausgetauscht werden, bis eine große Menge von Datensätzen (Big Data) gesammelt wurde. Anschließend werden die Daten in der Datenvorbereitung aufbereitet, indem Fehler korrigiert und Informationslücken gefüllt werden. Bei der Datenanalyse könnte die deskriptive Analytik dabei helfen, die Datenmengen zuerst so aufzubereiten, dass sich eine erste Transparenz abzeichnet und weitere Schritte leichter fortgesetzt werden können. Auf Basis der Vergangenheitswerte der Ist-Absätze und Marktinformationen könnten mittels explorativer Analytik und Data Mining Ansätzen mittels der beschriebenen Anwendung von Clustering versteckte Einflussfaktoren und Strukturen der Absatzzahlen gefunden werden, sodass neue Alternativen für den Planungsprozess generiert werden. Mit diesen Einflussfaktoren können, neben der klassischen Nutzung der exponentiellen Glättung, mit Regressionsanalysen der prädiktiven Analytik das Verhältnis zwischen Absatz und den Einflussfaktor festgestellt werden, sodass mit der Veränderung der Einflussfaktoren Prognosen für die Absatzzahlen erstellt werden können.⁹⁵ Demnach ermöglicht der Einsatz der explorativen Methoden neue

⁹⁵ Vgl. Wang, G. et al. 2016, S. 103; Vgl. Papp, S. et al. 2019, S. 260.

Entscheidungsalternativen zu definieren und gleichzeitig unter Einbezug eines großen Anteils von Parametern präzisere Prognosen der Zukunft zu planen.

Bei einem Anwendungsfall des globalen Chemieunternehmens BASF wurde eine Kombination aus der exponentiellen Glättung und der Regressionsanalyse angewandt, um die Vorteile beider Methoden zu nutzen. Dabei wurden zur Erweiterung der exponentiellen Glättungen Kovariaten oder auch Regressoren mit einbezogen. Diese Regressoren dienen dazu, die externen Einflussfaktoren wie z.B. Wetter, Feiertage und makroökonomische Faktoren abzubilden. Des Weiteren ist es in der Praxis, relevant Fehlerintervalle zu verwenden, da eine punktgenaue Prognose unrealistisch ist und zu Fehleinschätzungen führen kann. Bei der Auswahl eines ausreichenden Fehlerintervalls werden auch die Einschätzungen und Erfahrung der Mitarbeiter mit einbezogen. Die Ergebnisse der Studie haben gezeigt, dass die Nutzung von prädiktiver Analytik bei BASF dazu geführt hat, dass die Prognosepräzision in der Absatzplanung signifikant verbessert wurde und die Unsicherheiten in unterschiedlichen Unternehmensumgebungen reduziert wurden.⁹⁶

Bei der Untersuchung der Primärbedarfe und Kapazitätsbelastungen kann es in der Praxis zu Situationen kommen, wo der Ist-Bedarf von dem Soll-Bedarf abweicht, indem z.B. unverkäuflicher Ausschuss produziert wurde. Diese Unsicherheiten, die in unerwarteten Situationen vorkommen, können dazu führen, dass die Bedarfe abweichen und es zu einer schlechten Liefertreue kommen kann. Diese Abweichung muss in der Planung beachtet und eingeschätzt werden, damit die Planung an Robustheit gewinnt. Zu beachten ist dabei, dass die Untersuchung von Unsicherheiten bei einer systemübergeordneten Planung im Gegensatz zur Untersuchung eines Subsystems einer Werkstatt einen großen Rechenleistungsbedarf hat, insbesondere dann, wenn die Planungsgüte durch viele untersuchte Szenarien erhöht werden soll. In diesem Fall kann eine diskrete Ereignis-Simulationen zur Lösung eines Optimierungsmodells der Produktionsbedarfsplanung beitragen. Ein möglicher Ansatz wäre die Nutzung von Monte-Carlo-Simulationen zur prädiktiven Analyse der Situationen und der daraus entstehenden Folgen. Es könnten Szenarien untersucht werden, welche durch unsichere Parameter beeinflusst werden könnten. Dazu gehören die Bedarfe und der Ausschuss, der beim Produktionsprozesse entstanden ist und dem Kunden nicht verkauft werden kann. Um einen Einblick in die Entstehung der genannten unsicheren Parameter zu erhalten, sollten zur Aufbereitung einerseits eine deskriptive Analyse mit den Rohdaten durchgeführt werden. Andererseits muss untersucht werden, aus welchen Gründen die unsicheren Parameter entstehen,

⁹⁶ Vgl. Blackburn, R. et al. 2015, S. 418 ff.

um sie in den Simulationen realitätsnah einzuschätzen. Dafür könnten Ansätze aus der diagnostischen Analytik unterstützend eingesetzt werden, um eine bessere Erkenntnis über die unsicheren Parametern zu erlangen. Zuerst sollten die Simulationen dazu genutzt werden, um die Ursachen für den Ausschuss ausfindig zu machen, dabei können auch Klassifikationen helfen die Faktoren in Relation mit dem Ausschuss zu bringen. Wenn nachvollziehbar die Entstehung der Parameter nachvollziehbar festgelegt wurde, kann durch Ereignis-Simulationen das Optimierungsmodell iterativ auf die unsicheren Parameter angepasst werden, damit Primärbedarfe ermittelt werden können, die auch in unerwarteten Situationen, wie fehlerhafte Erzeugnisse, die Nachfragen der Kunden decken können. Durch die Nutzung dieser Methoden wird die Produktionsprogrammplanung robuster, weil die Einschätzungen und Prognosen des Primärbedarfes und der in Verbindung stehenden Ressourcen präziser werden. Durch die diagnostische Analytik findet auch eine Neubetrachtung der Kriterien zur Planung statt, da ein tieferes Verständnis über die Prozesse besteht.⁹⁷

4.2.2 Produktionsbedarfsplanung

Ähnlich wie bei der Ermittlung des Primärbedarfes können Unsicherheiten bei der Ermittlung des Sekundärbedarfes eine Rolle spielen. Anstatt den Ausschuss einer Produktion zu betrachten, müssen bei der Sekundärbedarfsermittlung Unsicherheiten in Form von fehlerhaften oder beschädigten Teilen, die vom Lieferanten stammen oder innerhalb des Betriebes beschädigt werden, einbezogen werden. In der Regel werden oft bedarfsorientierte Ermittlungen mittels Stücklisten durchgeführt, jedoch wird bei dieser Ermittlungsart nicht auf die Unsicherheiten Rücksicht genommen, auch dann, wenn es in der Vergangenheit es zu Problemen gekommen ist. Um einen sicheren Sekundärbedarf zu ermitteln, sollte der verbrauchsorientierte Ansatz priorisiert werden. Auch hier könnten auf Basis von Vergangenheitswerten ähnliche Analysen wie bei der Ermittlung des Primärbedarfes herangezogen werden. Zur Datenerfassung müssten einerseits die Verbräuche exakt dokumentiert werden. Dabei ist es ausgesprochen wichtig, Sonderfälle, wie die Anlieferung von fehlerhaften Teilen oder die Beschädigung von Teilen in der Produktion ausführlich zu dokumentieren. Hierbei sollte eine bekannte Schwäche der Produktionsplanung überwunden werden und eine digitale Dokumentation implementiert werden, damit die Transparenz im System besser gestaltet wird. Besondere Aufmerksamkeit sollte dabei den Gründen für die

⁹⁷ Vgl. Herrmann, F./Englberger, J. 2021, S. 58 f.

fehlerhaften und beschädigten Teilen gewidmet werden. Bei den beschädigten Teilen könnten moderne Maschinen detaillierte Informationen zu zahlreichen Parametern liefern, welche mit diagnostischer Datenanalyse und Simulationen aufzeigen können, warum es zu solchen Beschädigungen kam. Bei vermeidbaren Fehlern könnten die nötigen Maßnahmen in Kraft gesetzt werden. Sollte es zu unvermeidbaren Fehlern kommen, könnten Methoden der präskriptiven Analytik die Wahrscheinlichkeit dieser Fehler und deren Folgen in der Zukunft einschätzen und entsprechende Sicherheitsbestimmungen einkalkulieren. Um den fehlerhaften Teilen bei Lieferungen vorzubeugen, könnten auch Datenanalysen unterstützen. Heutzutage findet bei längeren Geschäftsbeziehungen ein weitgehender Datenaustausch zwischen Lieferanten und Kunden statt, sodass mit den richtigen Daten ähnliche Analysen durchgeführt werden könnten, um das Risiko von Fehllieferungen einzuschätzen. Durch die Nutzung der Data Analytics kann der zukünftige Ist-Bedarf präziser prognostiziert werden und wirkt sich positiv auf die Resilienz der Materialversorgung aus, sodass die Termintreue sichergestellt werden kann. Die Betrachtung von Unsicherheiten liefert neue Entscheidungsalternativen und ermöglicht es, die Wahrscheinlichkeit von Fehlern zu prognostizieren.⁹⁸

Bei der Beschaffungsartzuordnung wird eine wichtige strategische Entscheidung getroffen, welche die Wertschöpfungskette stark beeinflusst. Die bekannte Make-or-Buy-Problematik hat demnach einen hohen Wert für die Zukunft des Produktionssystems und wird bereits mit verschiedenen bekannten Analysemodellen wie z.B. der Total-Cost-of-Ownership-Berechnung betrachtet. Jedoch hat dieser Berechnung einen starken Kostenfokus, sodass andere signifikante Variablen nicht einbezogen werden. Hier könnte die These aufgestellt werden, dass eine präskriptive Datenanalyse die Entscheidungsqualität verbessern könnte. Mithilfe von Klassifikation und maschinellem Lernen könnte ein Entscheidungsbaum erstellt werden, der alle Wege des Baumes mit den signifikanten Variablen zur Make-or-Buy-Entscheidung verknüpft, solange bis alle Variablen verwendet werden. Dabei müssten Informationen über Kostenstrukturen, potenziellen Lieferanten, Kapazitäten, Transportkosten usw. beachtet werden. Die Variable mit dem größten Informations Gain könnte der Kostenvergleich darstellen, sodass dieser Vergleich als oberster Entscheidungsknoten genommen wird. Wenn der Entscheidungsbaum aufgestellt wurde, könnte mithilfe von Monte-Carlo-Simulationen die wirtschaftlich optimale Entscheidung über eine Optimierungsfunktion getroffen werden. Dieses Vorgehen würde es ermöglichen, viele Variablen und neue Kriterien in den Entscheidungsprozess einfließen zu lassen.

⁹⁸ Vgl. Zeisel, S. 2020, S. 26, Abs. 6.

Im nächsten Schritt der Durchlaufterminierung sollen erste Eckdaten für Fertigungsaufträge angeordnet werden, um rüstopimierte Kapazitätsgruppen zu bilden. Oft werden diese Kapazitätsgruppen nur nach gleicher oder ähnlicher Maschinenrüstung angeordnet, jedoch gibt es auch andere Merkmale, die die Durchlaufzeit beeinflussen können. Im Folgenden soll ein Ansatz beschrieben werden, der mittels explorativer Analytik (Data Mining) die signifikantesten und häufig unbekanntesten Faktoren der Durchlaufzeitoptimierung untersucht und somit eine bessere Transparenz in den Prozess bringt. Für diese Analyse werden typische Datensätze aus dem Fertigungsprozess benötigt, z.B. Fertigungsaufträge, Produkte, Vorgänger, Übergangszeiten. Weiterhin müssen auch untypische Merkmale der Fertigung aufgenommen werden, um potenzielle Durchlaufzeittreiber zu entdecken, die vorher nicht bekannt waren. Zu den untypischen Merkmalen können z.B. Qualitätsgrad, Werkstoff oder sogar Legierungskategorien gehören. Sind die Datensätze mit den genannten Merkmalen in großen Mengen gesammelt (Big Data), müssen diese aufbereitet werden, um Korrektheit und Vollständigkeit sicherzustellen. Für die explorative Datenanalyse wird eine Cluster-Methode verwendet, im hier abgebildeten Zusammenhang könnte auch Fuzzy-Clustering verwendet werden. Fuzzy-Clustering unterscheidet sich dadurch, dass die Objekte nicht einem einzigen sondern mehreren Clustern zugeordnet werden können. Das Clustering ordnet im Verlauf der Analyse jedem Objekt einen oder mehrere Cluster zu, dabei sind die Cluster nach starken Einflussgrößen bis hin zu schwachen Einflussgrößen gegenüber der Durchlaufzeit angeordnet. Die Ergebnisse könnten aufzeigen, dass der Vorgänger, wie erwartet, einen großen Einfluss durch Rüstprozesse auf die Durchlaufzeit hat, jedoch könnte auch ein unbekannter Durchlaufzeittreiber erkannt werden. Ein Beispiel könnte der verwendete Werkstoff sein, bei dem nach der Bearbeitung möglicherweise eine Reinigung der Maschine notwendig wird, wodurch sich die Durchlaufzeit erhöhen würde. Mit den neu erlangten Erkenntnissen könnten Planungsregeln und Kriterien formuliert werden, welche während der Durchlaufterminierung dazu führen, einen besseren Plan aufzustellen, sodass die Durchlaufzeit und die Produktionseffizienz verbessert wird.⁹⁹

Im Aufgabenbereich der Kapazitätsabstimmung ist keine direkte Anwendung von Data Analytics zu erkennen. Trotzdem könnten Methoden der Data Analytics helfen die Kapazitätsermittlung flexibler zu gestalten. In der klassischen Ermittlung werden festgelegte Stückzeiten mit den Stückzahlen multipliziert, um den Kapazitätsbedarf der Planungsperiode zu ermitteln. Diese Herangehensweise hat einen statischen Charakter und könnte bei

⁹⁹ Vgl. Rainer, C. 2012, S. 355 f.

Schwankungen im Leistungsvermögen zu falschen Einschätzungen führen. Die genannten Leistungsschwankungen könnten ihren Ursprung in unterschiedlichsten Faktoren der Maschinen, Transportprozesse bis hin zum Personal haben. Um diesen Aspekt mit in die Kapazitätsermittlung einfließen zu lassen, müssten zuerst historische Daten über das Leistungsvermögen des Arbeitssystems gesammelt werden. Mithilfe der erstellten Kennzahlen der deskriptiven Analytik können die Prozesse in einer quantitativen Form beschrieben werden. Ähnlich wie in der Durchlaufterminierung können auch hier Clustering-Methoden der explorativen Analytik verwendet werden, um unbekannte Faktoren ausfindig zu machen, die möglicherweise einen signifikanten Einfluss auf das Leistungsvermögen haben. Diese bisher ignorierten Einflussfaktoren könnten mittels Planungsregeln und neuen Kriterien dazu beitragen, die Kapazitätsermittlung und so auch die Produktionseffizienz zu optimieren. Sollte es trotzdem zu Fällen kommen, bei denen das Kapazitätsvermögen nicht dem Soll-Wert entspricht, könnten Methoden der diagnostischen Analytik unterstützend eingesetzt werden, um die Gründe der Schwankungen im System ausfindig zu machen, sodass Maßnahmen eingesetzt werden könnten, um die Schwankungen einzudämmen.

4.2.3 Eigenfertigungsplanung und Fremdbezugsplanung

Der erste Schritt bei der Eigenfertigungsplanung besteht darin, die optimale Losgröße zu berechnen. Dafür wird in der Regel das Modell von Andler für eine erste Einschätzung hinzugezogen. Das Ziel einer optimalen Produktion ist es, eine Losgröße von eins anzustreben, da so die Flexibilität ausgeschöpft werden kann, jedoch steht die hohe Flexibilität mit hohen Rüstzeiten in Verbindung. Demnach muss eine Losgröße ermittelt werden, die das optimale Zusammenspiel zwischen den logistischen Zielgrößen und allen Faktoren, die das Produktionssystem beinhaltet zusammenfassen. Um eine ganzheitliche Betrachtung der Reaktionen des Produktionssystems auf die Losgröße zu ermöglichen, können umfangreiche Modelle in der diagnostischen Analytik erstellt werden. Eine Simulation über dieses Modell ermöglicht es in mehreren Durchläufen ein weites Spektrum an möglichen Losgrößen zu untersuchen. Dabei können Faktoren wie Staus auf Förderstrecken, Lagerbestände und Störungen dargestellt werden. Darüber hinaus kann zwischen Push und Pull-Prinzip unterschieden werden. Nach erfolgreicher Simulation der Losgrößen und Verfahren können die Ergebnisse betrachtet werden und nach Zielgrößen, wie der Durchlaufzeit, Flexibilität und

Lagerhaltungskosten analysiert werden.¹⁰⁰ Mit dieser Anwendung der diagnostischen Analytik kann im Gegensatz zur Andler-Formel, welche nur Lager- und Bestellkosten betrachtet, das ganze Produktionssystem mit all seinen Ausprägungen auf eine optimale Losgröße untersucht werden. Dies ermöglicht es die Produktionseffizienz und Durchlaufzeit in Verbindung mit kostenoptimalen Beständen zu erhöhen.

Die Feinterminierung plant die Fertigungsaufträge an die Zeit- und Kapazitätsanforderungen und erstellt den operativeren Maschinenbelegungsplan. Einer der größten Herausforderungen bei der kurzfristigen Produktionsplanung besteht darin, auf Störungen zu reagieren und Pläne umzustellen. Dabei sind Störungen oft überraschend und es werden dazu wenig Indikatoren für eine Störanfälligkeit identifiziert. Durch die Verwendung von prädiktiver Datenanalytik können Störindikatoren untersucht werden und darauf basierend dieser präventive Wartungen durchgeführt werden, welche frühzeitig in die Feinterminierung eingeplant werden können. Die nötige Datenerfassung können moderne Produktionsmaschinen mit integrierter Sensorik oft schon selbst liefern. Es besteht auch die Möglichkeit, Sensoren zur Datenerfassung aufzurüsten, sodass die Maschinentransparenz gewährleistet ist. Während die deskriptive Analytik ein klares Bild in einer gesammelten Datenmenge ermöglicht, wird die diagnostische Analytik dazu angewendet, um zu erkennen, warum es zu vergangenen Störungen kam. Einerseits könnten Klassifikationen verwendet werden, um die Merkmale in Klassen einzuteilen, die eine hohe oder geringe Korrelation zur Störung aufzeigen. Dabei werden schleichende Veränderungen im Verhalten gesucht. Beispielweise könnten allmählich steigende Temperaturen durch Reibung oder zunehmende Schwingungen von sich lösenden Teilen dazu führen, dass eine Wartung durchgeführt werden muss. Sollten solche Merkmale im laufenden Betrieb erkannt werden, können prädiktive Analysen mit Regressionsanalysen einschätzen, wann es zur Störung kommen könnte, um eine präventive Wartung durchzuführen. Dabei könnten auch multiple Regressionsanalysen durchgeführt werden, um die verschiedenen Störungsindikatoren in die Einschätzung einfließen zu lassen.¹⁰¹ Mit der ausführlichen Sensorik der Maschinen lässt sich die Transparenz signifikant steigern, woraus durch präventive Wartungen die Durchlaufzeit und Liefertreue gesichert werden können. Darüber hinaus können durch detaillierte Analysen sogar Faktoren zur Qualitätssicherung untersucht werden. Ähnliche Anwendungsbeispiel aus der Praxis liefern Unternehmen wie Thyssen Krupp, DB Schenker und GE Aviation. Diese

¹⁰⁰ Vgl. Simon, C. et al. 2021, S. 27 ff.

¹⁰¹ Vgl. Schöning, H./Dorchain, M. 2014, S. 545.

Unternehmen nutzen Big Data Analysis, um präventive Wartungen für Transportmittel und Fahrstühle durchzuführen.¹⁰²

Ähnlich wie bei der Kapazitätsabstimmung der Produktionsbedarfsplanung berücksichtigt die Ressourcenfeinplanung die Feinplanung unter Einbezug der Kapazitäten. Auch hier werden Kapazitäten ermittelt. Aus diesem Grund sind die Schwachstellen und das Potenzial ähnlich zu betrachten. Die Verwendung von deskriptiver, explorativer sowie diagnostischer Analytik kann einen Einblick in die Leistungsstrukturen ermöglichen, sodass die Kapazitätsermittlung auch in der kurzfristigen Eigenfertigungsplanung optimiert werden kann.

In der Reihenfolgeplanung werden auf der operativen Ebene in der Praxis Regeln, wie das FIFO-Prinzip, das keinen großen Aufwand erzeugt, angewendet. Auch bei der Reihenfolge können Simulationen der diagnostischen Analytik optimale Pläne erstellen. Bei der Deere GmbH & Co. KG in Mannheim wurden Simulationen mit einem genetischen Algorithmus und Reihenfolgebeschränkungen zur Untersuchung der Reihenfolgeoptimierung durchgeführt. Dabei hatte die Optimierung das Ziel die Zykluszeit der zu montierenden Produktreihenfolge zu minimieren. Um die Zykluszeiten zu bestimmen, wurden Simulationsmodelle erstellt, die Ergebnisdaten gesammelt und ausgewertet haben. Als Nebenbedingungen wurden Restriktionen der Reihenfolge mitberücksichtigt. Der verwendete Optimierungsalgorithmus hat in den Simulationen mehrere Optimierungsdurchläufe absolviert, bis die Zielgröße keine positive Entwicklung mehr aufgezeigt hat. Die Optimierungsdurchläufe wurden so ausgerichtet, dass der Algorithmus bei den Durchläufen immer neue Startreihenfolgen von Aufträgen untersucht hat. Darüber hinaus wird stets geprüft, ob die vorgegebenen Restriktionen eingehalten wurden. Durch die Lernfähigkeit des genetischen Algorithmus konnte die Zykluszeit auf einem optimalen Niveau gehalten und somit auch die optimale Reihenfolgeplanung gestellt werden.¹⁰³ Durch den Erfolg einer solchen Untersuchung können die Durchlaufzeit und Produktionseffizienz verbessert werden, zusätzlich können zahlreiche Reihenfolgealternativen für die Planung betrachtet und bewertet werden.

Die Aufgabe der Bestellrechnung in der Fremdbezugsplanung hat das Ziel die ideale Bestellmenge für einen optimierten Bestand zu halten, der jegliche Bedarfe absichern kann und zugleich geringe Lagerhaltungskosten aufweist. Dabei wird die Formel vom Grundmodell von A德勒, welches schon bei Losgrößenberechnung verwendet wurde, abgeleitet. Die oben beschriebene Rechnung dient dabei nicht als endgültige Entscheidung für das

¹⁰² Vgl. Wrona, T./Reinecke, P. 2019, S. 449.

¹⁰³ Vgl. Lemessi, M. 2013, S. 87 ff.

Bestandsmanagement, sondern bietet nur eine erste Hilfestellung. Die Optimierung des Bestandes beinhaltet wesentlich mehr Faktoren, als die Formel betrachtet. Mit Transparenz in der ganzen Lieferkette und prädiktiven Analysen lässt sich der Bestand so optimieren, dass die Funktion als Puffer trotzdem nicht verloren geht. Ziel der Anwendung ist es, Informationen der gesamten Lieferkette in Echtzeit einsehen zu können und mit diesen Daten die Lieferkette durch das Modell eines sog. digitalen Zwillings zu simulieren. Die nötige Datenerfassung muss sich dabei beginnend beim Lieferanten, über das eigene System bis zum Kunden durchziehen.¹⁰⁴ Die Informationen, welche im digitalen Zwilling enthalten sind, könnten durch deskriptive Analytik in einer digitalen Maske einsehbar und transparent dargestellt werden. Der Einsatz eines digitalen Zwillings vereinfacht auch die Ausführung von Simulationen zur diagnostischen Analyse. Demnach können Input-Datensätze dem Modell eingefügt werden und analysiert werden, wie sich der digitale Zwilling verhält. Diese Einsicht erlaubt die Indikatoren für Schwankungen in der Nachfrage zu identifizieren und versorgt damit die prädiktive Analytik. Die prädiktive Analytik mit Simulationen dient dazu, die Bedarfe sowie Bedarfsveränderungen der Kunden rechtzeitig zu prognostizieren und die Bestände mit einem kalkulierten Puffer präzise anzupassen. Diese Anwendung ermöglicht es die Bestände bei gleicher Bedarfsabdeckung schlanker zu gestalten, zusätzlich werden Lagerhaltungskosten und Kapitalbindung im Bestand reduziert. Zuletzt können mit den verwendeten Data Analytics Anwendungen optimale, flexible Bestellmengen ermittelt werden, welche die Bestände optimiert und gleichzeitig eine hohe Transparenz in der Supply Chain bietet.

Im wichtigsten Schritt der Fremdbezugsplanung werden Lieferantenangebote bewertet und ein Lieferant ausgewählt. Dabei können mehrere Anwendungsmöglichkeiten der Data Analytics den Bewertungsprozess unterstützen. Zuerst müssen potenzielle Lieferanten im Markt identifiziert und qualifiziert werden. Dabei lohnt es sich, eine Beschaffungsmarktanalyse durchzuführen. Hierbei können zur Datenerfassung einerseits Internet-Suchen mit semantischen Verfahren unterstützen, andererseits gibt es IT-Werkzeuge zur Lieferantensuche, die Zugriff auf unternehmensübergreifende Lieferantenstammdaten haben. Wenn eine Liste von sämtlichen potenziellen Lieferanten erstellt wurde, können durch Klassifikation alle Lieferanten vordefinierten Klassen zugeordnet werden.¹⁰⁵ Im nächsten Schritt müssen Preise und Leistungen der Lieferanten bewertet werden. Nach einer deskriptiven Analyse können Preise und Lieferantenperformance in Kennzahlen dargestellt werden. Eine umfangreiche

¹⁰⁴ Vgl. Zeisel, S. 2020, S. 28, Abs. 13.

¹⁰⁵ Vgl. ebenda, S. 25, Abs. 4.

Datensammlung ermöglicht es, Leistungskennzahlen von Lieferanten fortlaufend zu überwachen, sodass bei Unterschreitung von Zielwerten Meldungen entstehen.¹⁰⁶ Bei der Erfassung der Preise können zusätzlich diagnostische Analysen zur Preisstruktur und Preisbildung durchgeführt werden, die schon in Automobilkonzernen bei wichtigen Beschaffungsteilen verwendet werden. Die Preisstrukturanalyse versucht die Bildung des Angebotspreises nachzuvollziehen. Erstens werden die Materialkosten nach physikalischer Größe oder Gewicht und anhand der verfügbaren Rohstoffpreise ermittelt. Zweitens werden durch Befragungen von Experten Daten erfasst, die es ermöglichen, die Kosten für Arbeits- und Maschinenstunden einzuschätzen. Drittens wird eine Zuschlagskalkulation mit administrativem Aufwand und einer angemessenen Gewinnspanne addiert. Zuletzt werden die Angebotspreise mit den Ergebnissen der Preisstrukturanalyse verglichen.¹⁰⁷ Die bis hierher verwendeten deskriptiven und diagnostischen Ansätze betrachten nur vergangene und aktuelle Informationen. Sollte es sich bei der Lieferantenwahl um Entscheidungen für langfristige Lieferantenbeziehungen handeln, sollten auch Trends für die Zukunft bewertet werden. Im Sinne der präskriptiven Analytik können auch Preistrends für Beschaffungsteile und Rohstoffe untersucht werden.

Zur prädiktiven Analyse der Preistrends werden historische Datensätze der Preise von Lieferanten benötigt. Sollten diese nicht verfügbar sein, können über Preisstrukturanalysen und historischen Rohstoffpreisen Einschätzungen aufgestellt werden. Um einen Trend der Preise zu prognostizieren, können multiple Regressionsanalysen durchgeführt werden, die Merkmale wie Nachfrage, Angebot sowie Preisuntergrenzen ins Verhältnis zum Preis setzen. Mit der erstellten Regression können Veränderungen des Preises anhand der genannten Merkmale prognostiziert werden.¹⁰⁸

Wenn jegliche vergangenheits- und zukunftsbezogenen Analysen zur Bewertung der Lieferantenangebote durchgeführt wurden, muss eine Entscheidung getroffen werden. Zur Unterstützung könnten aus der präskriptiven Analytik Entscheidungsbäume hinzugezogen werden, die die unterschiedlichen Faktoren aus den Preis- und Leistungsanalysen zusammenfassen, sodass mit einer Optimierungsfunktion die ideale Entscheidung getroffen werden kann. Dieser ausführliche Prozesse liefert eine hohe Transparenz in Lieferanten und

¹⁰⁶ Vgl. ebenda, S. 30, Abs. 18.

¹⁰⁷ Vgl. ebenda, S. 26, Abs. 7.

¹⁰⁸ Vgl. ebenda, S. 25 f., Abs. 5.

Kostenstruktur im der Lieferantenbewertung. Die Lieferantenauswahl profitiert an den zahlreichen bewerteten Alternativen und Prognosen für langfristige Lieferbeziehungen.

5 Fazit und Ausblick

Mit den vorgestellten Analytik-Methoden der Data Science und Analytics können die Kernaufgaben der Produktionsplanung nach dem Aachner PPS-Modell unterstützt werden. Data Analytics ist in der Lage durch die deskriptive Analytik mit stochastischen Verfahren die gesammelten Datenmengen aus einem Großteil der Kernaufgaben transparent darzustellen, sodass Erkenntnisse generiert werden können und zugleich das Fundament für nachfolgende Analyseschritte gelegt wird. Die Weiterentwicklung der explorativen Analytik zeigt auf, dass die Nutzung von unüberwachtem maschinellen Lernen wertvolle Zusammenhänge und Strukturen in den Daten identifizieren können, die zuvor nicht bekannt waren. Die daraus entstehenden Einflussfaktoren bieten oft einen effizienteren Weg die logistischen Zielgrößen einzuhalten. Die diagnostische Analytik kann mit Simulationen, die das ganze Produktionssystem abbilden und zielgerichteten Optimierungsfunktionen die Produktionsplanung verbessern, indem z.B. ideale Losgrößen und Reihenfolgeplanungen für jede individuelle Produktion untersucht werden können. Darüber hinaus ermöglicht sie den Ursprung von Problemen zu ergründen, sodass Maßnahmen zur Vermeidung proaktiv angewendet werden können. Die prädiktive Analytik hat den größten Wert für einen Planungsprozess, da eine große Herausforderung bei einer Planung das Geschehen in der Zukunft ist. Durch die Nutzung von Big Data und präzisen Prognosemethoden können z.B. Maschinenausfälle und Nachfrageschwankungen prognostiziert werden, sodass die Planungsrobustheit gegenüber der Zukunft widerstandsfähiger ausfällt. Des Weiteren wurde in dieser Arbeit nur ein Ausschnitt der möglichen Data Analytics Methoden dargestellt. Data Analytics bietet für viele unterschiedliche Szenarien und Problemstellungen kompatible Analyseverfahren, die ein breites Spektrum an Effektivität und Aufwand aufweisen.

Werden die klassischen Methoden der PPS mit den Unterstützungen aus Data Science und Data Analytics verglichen, können einige Vorteile für die Planungsqualität ermittelt werden. Erstens können Schwachstellen der PPS verbessert werden. Die Datenerfassung über die ganze Wertschöpfungskette, die Sensorik der Maschinen sowie die Nutzung von Simulationen des Produktionssystems wie z.B. das Konzept des digitalen Zwilling bietet eine sehr viel höhere Transparenz und Kontrolle von Status und Qualität. Dabei besteht auch die Möglichkeit, mit einer ausgeprägten Datenstruktur die Transparenz mit Echtzeitdatenaustausch aufrecht zu

erhalten. Des Weiteren können Produktionseffizienz, Durchlaufzeiten und Termintreue durch optimalen Fertigungsreihenfolgen, eine bessere Kapazitätsermittlung, eine optimale Losgröße und präventive Wartungen sichergestellt werden. Hinzu kommen Einschätzungen von Schwankungen oder Unsicherheiten sowie optimierte Bestellmengen, die dafür sorgen den Bestand mit seinen Kosten und Kapitalbindung gering zu halten. Data Analytics ist bei dieser Betrachtung jedoch nicht in der Lage die Komplexität des System zu reduzieren. Durch maschinelles Lernen und Simulationen bietet sie nur eine Möglichkeit besser mit dynamischen und komplizierten Zusammenhängen umzugehen und trotzdem optimierte Entscheidungen treffen zu können. Um die Komplexität zu verringern, müssen andere Ansätze wie z.B. die Dezentralisierung der Planungseinheit angewendet finden.

Bei den Faktoren der Planungsqualität wird die Qualität der Prognosen durch die prädiktive Analytik erhöht. Es werden viele unterschiedliche Faktoren einbezogen und teilweise neue Einflussfaktoren durch die explorative Analytik entdeckt. Durch diese Erkenntnisse können auch neue Alternativen aufgestellt und bewertet werden. Das Problem der Definition und Bewertung von zahlreichen Alternativen wird in dieser Betrachtung von Algorithmen und maschinellem Lernen gut bewältigt. Weiterhin können die richtigen Kriterien und Optimierungsfunktionen dazu beitragen, dass die ideale Alternative ausgewählt wird und somit die logistischen Ziele eingehalten werden können. Dabei ist das Problem der Mehrdeutigkeit oder Gegensätzlichkeit der Kriterien, vor Allem im logistischen Zielsystem nicht gelöst. Trotzdem bieten Verfahren wie Simulationen die Möglichkeit auch die gegensätzlichen Kriterien in unterschiedlichen Ausprägungen zu untersuchen und diese Ergebnisse in Entscheidungen zu beachten. Auch bei komplexen Entscheidungsaufgaben liefert die präskriptive Analytik Methoden eine Möglichkeit einen Großteil der signifikanten Merkmale und Ausprägungen in die Entscheidung einfließen zu lassen, damit optimale Entscheidungen getroffen werden können.

Zusammenfassend wird die Planungsqualität der Produktionsplanung eines Industrieunternehmens mit Data Science und Analytics Methoden verbessert und bietet für heutige Unternehmen einen Wettbewerbsvorteil, der nicht vernachlässigt werden sollte. Deshalb ist es wichtig das „Data-Science-Know-How“ der Mitarbeiter auszubauen, um für die zukünftigen Herausforderungen der Wirtschaft gewappnet zu sein und bei disruptiven Technologien wie der KI partizipieren zu können.

Die hier beschriebene Data Analytics und Infrastruktur ist ein wichtiger Bestandteil der Industrie 4.0 und genießt eine große Präsenz in Form von Business Analytics oder Business

Intelligence. Aus diesem Grund ist die Forschung in den Bereichen wie z.B. Data Mining und maschinelles Lernen beschleunigt und liefert kontinuierlich neue Ansätze. Neben der Entstehung von neuen Analysemethoden, werden auch jegliche Datenkanäle in den Datenpool integriert. Spracherkennung, Textmining oder die Nutzung des gigantischen World Wide Webs bieten Datenmengen, die noch nicht voll in die Analysen integriert wurden.¹⁰⁹

Um die wertvollen Datenanalysen schneller oder sogar parallel in Echtzeit durchzuführen, liefern auch Forschungen aus dem Bereich Computing vielversprechende Ergebnisse, die eine neue Art der Daten Analytik ermöglichen. Die weiterentwickelte kognitive Analytik ist eine neue Herangehensweise und versucht die Aufgabenbereiche der Data Analytics mit dem aktuellen Stand des Computing zu vereinen. Dabei bewegt sich diese Art der Data Analytics im Umfeld des kognitiven Computing, welches aus fünf Bestandteilen besteht. Erstens werden Hochleistungsrechnerinfrastrukturen verwendet, die mit Multicore-Prozessoren und neuromorphen Chips versorgt sind. Neuromorphe Chips weisen, ähnlich wie beim künstlichen neuronalen Netz, eine Neuronen- und Synapsenstruktur auf, die nicht wie im klassischen Computing mit linearen Prozessen arbeitet, sondern in einem sich selbst optimierenden Netzwerk. Dabei werden diese neuartigen Chips als Meilenstein in der KI-Forschung angesehen.¹¹⁰ Zweitens werden Softwarelösungen, wie parallel und distributed Computing verwendet, um die Leistungsfähigkeit auch auf dieser Ebene zu erhöhen, damit Big Data angewandt werden kann. Drittens werden Softwarebibliotheken und Algorithmen des maschinellen Lernens zum Extrahieren von Informationen und Wissen aus unstrukturierten Datenmengen. Viertens wird Data Analytics Umgebungen geschaffen, die sich dem kognitiven Prozess des Menschen annähern und fünftens werden Abfragesprachen und Applikationen zur Nutzung der kognitiven Computing Umgebung verwendet.¹¹¹

¹⁰⁹ Vgl. Otte, R. et al. 2020, S. 451 ff.

¹¹⁰ Vgl. Pastur-Romay, L. et al. 2016, Abs. 3.

¹¹¹ Vgl. Gudivada, V.N. et al. 2016, S. 169 f.

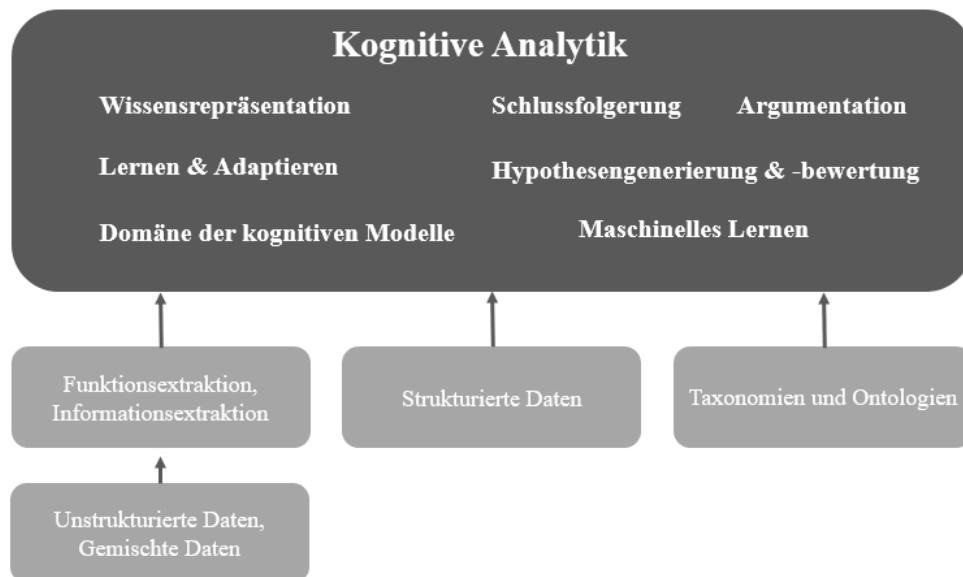


Abbildung 17: Konzept der kognitiven Analytik¹¹²

Die kognitive Analytik nutzt die Möglichkeiten des kognitiven Computings um Analysen von diversen, heterogenen Datenquellen durchzuführen. Dabei können die Daten in unstrukturierter, strukturierter und semistrukturierter Form vorkommen. Darüber hinaus werden Wissensstrukturen wie Taxonomien und Ontologien genutzt, um die Argumentation und Schlussfolgerung zu ermöglichen (s. Abbildung 17). Dies bedeutet, dass der Computer in der Lage ist, bei einer Entscheidung eigene Argumente für die Alternativen zu entwickeln, diese zu bewerten, zu vergleichen und eine Schlussfolgerung zu ziehen. Um das System lernfähig und adaptionsfähig zu gestalten, werden auch Komponenten des maschinellen Lernens implementiert. Die Domäne der kognitiven Modelle beinhaltet die kognitiven Problemlösungsprozesse. Im Gegensatz zur klassischen Analytik, welche deterministische Algorithmen verwendet, ist die kognitive Analytik in der Lage mehrere nach Relevanz geordnete Antworten auf eine Frage zu entwickeln, wofür die Komponente der Hypothesengenerierung und -validierung zuständig ist. Es werden für eine Frage mehrere Hypothesen aufgestellt und Beweise gesucht, mit denen die Antworten bewertet werden können. Die Möglichkeiten der kognitiven Analytik zeigen auf, dass die Data Science und Analytik in der Zukunft das Potenzial dazu hat, den größten Teil der geschäftsrelevanten Entscheidungen unter Einbezug zahlreiche Parameter parallel in Echtzeit zu optimieren.¹¹³

¹¹² in Anlehnung an ebenda, Abb. 2.

¹¹³ Vgl. ebenda, S. 176 f.

Literaturverzeichnis

- Basu, A. (2013):** Five Pillars of Prescriptive Analytics Success In: *Analytics - Executive Edge*, 2013: 6, DOI: 10.1287/LYTX.2013.02.07.
- Bennett, N./Lemoine, G.J. (2014):** What a Difference a Word Makes: Understanding Threats to Performance in a VUCA World In: *Business Horizons*, 57 (3): 311–317, DOI: 10.1016/j.bushor.2014.01.001.
- Blackburn, R./Lurz, K./Priese, B./Göb, R./Darkow, I.-L. (2015):** A Predictive Analytics Approach for Demand Forecasting in the Process Industry: R. Blackburn In: *International Transactions in Operational Research*, 22 (3): 407–428, DOI: 10.1111/itor.12122.
- Cleff, T. (2011):** Deskriptive Statistik und moderne Datenanalyse: eine computergestützte Einführung mit Excel, PASW (SPSS) und STATA, 2., überarb. und erw. Aufl Wiesbaden: Gabler Verl., Springer Fachmedien, DOI: 10.1007/978-3-8349-7071-8.
- Dr. Thomas + Partner GMBH & CO. KG (2019):** Es fehlt an „Data-Science-Know-How“ In: *Logistik für Unternehmen*, 33 (09): 18–19, DOI: 10.37544/0930-7834-2019-09.
- Frazzetto, D./Nielsen, T.D./Pedersen, T.B./Šikšnys, L. (2019):** Prescriptive Analytics: A Survey of Emerging Trends and Technologies In: *The VLDB Journal*, 28 (4): 575–595, DOI: 10.1007/s00778-019-00539-y.
- Haasis, H.-D. (2008):** Produktions- und Logistikmanagement: Planung und Gestaltung von Wertschöpfungsprozessen, 1. Aufl Wiesbaden: Gabler, DOI: 10.1007/978-3-8349-9784-5.
- Hazen, B.T./Boone, C.A./Ezell, J.D./Jones-Farmer, L.A. (2014):** Data Quality for Data Science, Predictive Analytics, and Big Data in Supply Chain Management: An Introduction to the Problem and Suggestions for Research and Applications In: *International Journal of Production Economics*, 154: 72–80, DOI: 10.1016/j.ijpe.2014.04.018.
- Knuth, T. (2021):** Lernende Entscheidungsbäume: Überholtes Verfahren oder vielseitige KI-Methode? In: *Informatik Spektrum*, 44 (5): 364–369, DOI: 10.1007/s00287-021-01398-0.
- Larose, D.T. (2006):** Data Mining Methods and Models Hoboken, NJ: Wiley-Interscience, DOI: 10.1002/0471756482.
- Pastur-Romay, L./Cedrón, F./Pazos, A./Porto-Pazos, A. (2016):** Deep Artificial Neural Networks and Neuromorphic Chips for Big Data Analysis: Pharmaceutical and Bioinformatics Applications In: *International Journal of Molecular Sciences*, 17 (8): 1313, DOI: 10.3390/ijms17081313.

- Rainer, C. (2012):** Wissensbasierte Produktionsplanung in der flexibilitätsorientierten Prozessindustrie In: *BHM Berg- und Hüttenmännische Monatshefte*, 157 (8–9): 354–359, DOI: 10.1007/s00501-012-0030-y.
- Schuh, G./Reuter, C./Prote, J.-P./Brambring, F./Ays, J. (2017):** Increasing Data Integrity for Improving Decision Making in Production Planning and Control In: *CIRP Annals*, 66 (1): 425–428, DOI: 10.1016/j.cirp.2017.04.003.
- Sihn, W./Sunk, A./Nemeth, T./Kuhlang, P. (2016):** Produktion und Qualität, 1 München: Carl Hanser Verlag, DOI: 10.3139/9783446449916.
- Simon, C./Haag, S./Zakfeld, L. (2021):** Simulation taktgesteuerter Modelle von Push- und Pull-Prozessen in der Logistik In: *Anwendungen und Konzepte in der Wirtschaftsinformatik*, 2021 (13): 27–33.
- Wagner, E. (2019):** Smart Data und die Intralogistik In: *Logistik für Unternehmen*, 33 (07/08): 6–9, DOI: 10.37544/0930-7834-2019-07-08-6.
- Wang, G./Gunasekaran, A./Ngai, E.W.T./Papadopoulos, T. (2016):** Big Data Analytics in Logistics and Supply Chain Management: Certain Investigations for Research and Applications In: *International Journal of Production Economics*, 176: 98–110, DOI: 10.1016/j.ijpe.2016.03.014.
- Wiendahl, H.-P./Wiendahl, H.-H. (2020):** Betriebsorganisation für Ingenieure, 9., vollständig überarbeitete Auflage München: Hanser, DOI: 10.3139/9783446460614.
- Barton, T./Müller, C. (2021):** Data Science: Vom Begriff zu Anwendung In: Barton, T. und Müller, C. (Hrsg): *Data Science anwenden: Einführung, Anwendungen und Projekte*. Wiesbaden: Springer Fachmedien Wiesbaden, 3–12. Online im Internet: <https://link.springer.com/10.1007/978-3-658-33813-8>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-33813-8.
- Chamoni, P. (2021):** Data Science – Entwicklungslinien und Trends In: Frick, D./Gadatsch, A./Kaufmann, J./Lankes, B. et al. (Hrsg): *Data Science: Konzepte, Erfahrungen, Fallstudien und Praxis*. Wiesbaden: Springer Fachmedien Wiesbaden, XIII–XVI. Online im Internet: <https://link.springer.com/10.1007/978-3-658-33403-1>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-33403-1.
- Deru, M./Ndiaye, A./Kiefer, G.-L./Baus, J./Gampfer, R. (2021):** Integration erneuerbarer Energien – KI-basierte Vorhersageverfahren zur Stromerzeugung durch Photovoltaikanlagen In: Barton, T. und Müller, C. (Hrsg): *Data Science anwenden: Einführung, Anwendungen und Projekte*. Wiesbaden: Springer Fachmedien Wiesbaden, 147–170. Online im Internet: <https://link.springer.com/10.1007/978-3-658-33813-8>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-33813-8.
- Fleischmann, B./Meyr, H./Wagner, M. (2015):** Advanced Planning In: Stadtler, H./Kilger, C. und Meyr, H. (Hrsg): *Supply Chain Management and Advanced Planning: Concepts, Models, Software, and Case Studies*. Berlin, Heidelberg: Springer Berlin Heidelberg, 71–98. Online im Internet: <http://link.springer.com/10.1007/978-3-642-55309-7>, Stand: 08.12.2021, DOI: 10.1007/978-3-642-55309-7.

- Frochte, J. (2020):** Maschinelles Lernen: Grundlagen und Algorithmen in Python, 3 München: Carl Hanser Verlag GmbH Co KG. Online im Internet: <https://d-nb.info/1221889583>.
- Grabner, T. (2012):** Operations Management Wiesbaden: Springer Fachmedien Wiesbaden. Online im Internet: <http://link.springer.com/10.1007/978-3-658-00183-4>, Stand: 09.12.2021, DOI: 10.1007/978-3-658-00183-4.
- Gudivada, V.N./Irfan, M.T./Fathi, E./Rao, D.L. (2016):** Cognitive Analytics: Going Beyond Big Data Analytics and Machine Learning In: Gudivada, V.N./Raghavan, V.V. und Govindaraju, V. (Hrsg): Handbook of Statistics: Cognitive Computing: Theory and Applications. : Elsevier, 169–205. Online im Internet: <https://linkinghub.elsevier.com/retrieve/pii/S0169716116300517>, Stand: 28.01.2022, DOI: 10.1016/bs.host.2016.07.010.
- Herrmann, F./Englberger, J. (2021):** Robuste Optimierung zur Produktionsprogrammplanung In: Claus, T./Herrmann, F. und Manitz, M. (Hrsg): Produktionsplanung und -steuerung: Forschungsansätze, Methoden und Anwendungen. Berlin, Heidelberg: Springer Berlin Heidelberg, 39–61. Online im Internet: <https://link.springer.com/10.1007/978-3-662-64291-7>, Stand: 24.11.2021, DOI: 10.1007/978-3-662-64291-7.
- von der Hude, M. (2020):** Predictive Analytics und Data Mining Wiesbaden: Springer Fachmedien. Online im Internet: https://doi.org/10.1007/978-3-658-30153-8_1, Stand: 02.12.2021, DOI: 10.1007/978-3-658-30153-8_1.
- Kaufmann, U.H./Tan, A.B.C. (2021):** Data Science für Einsteiger: Daten analysieren, interpretieren und richtige Entscheidungen treffen München: Carl Hanser Verlag GmbH & Co. KG. Online im Internet: <https://d-nb.info/1210296926>.
- Kellner, F./Lienland, B./Lukesch, M. (2020):** Produktionswirtschaft: Planung, Steuerung und Industrie 4.0 Berlin, Heidelberg: Springer Berlin Heidelberg. Online im Internet: <http://link.springer.com/10.1007/978-3-662-61446-4>, Stand: 09.12.2021, DOI: 10.1007/978-3-662-61446-4.
- Kletti, J./Schumacher, J. (2014):** Die perfekte Produktion, 2 Berlin, Heidelberg: Springer Berlin Heidelberg. Online im Internet: <http://link.springer.com/10.1007/978-3-662-45441-1>, Stand: 09.12.2021, DOI: 10.1007/978-3-662-45441-1.
- Lemessi, M. (2013):** Simulationsbasierte Reihenfolgeoptimierung von Fertigungsaufträgen für Montagesysteme mittels eines genetischen Algorithmus unter Beachtung von Reihenfolgebeschränkungen In: Dangelmaier, W./Laroque, C./Klaas, A. und Gesellschaft für Informatik (Hrsg): Simulation in Produktion und Logistik 2013: Entscheidungsunterstützung von der Planung bis zur Steuerung. Paderborn: Heinz-Nixdorf-Inst., Univ. Paderborn, 87–97. Online im Internet: <https://www.asim-gi.org/publikationen/asim-spl-tagungsbaende/detail/proceedings-asim-2013-conference-simulation-in-production-and-logistics-2013-paderborn-2013-am147>.
- Lödding, H. (2016):** Verfahren der Fertigungssteuerung, 3 Berlin, Heidelberg: Springer Berlin Heidelberg. Online im Internet: <http://link.springer.com/10.1007/978-3-662-48459-3>, Stand: 08.12.2021, DOI: 10.1007/978-3-662-48459-3.

- Lünendonk, J. (2019):** Lünendonk®-Studie 2019 - Künstliche Intelligenz: Eine Studie zum Status quo in deutschen Unternehmen und zu zukünftigen Anwendungsfällen In: Lünendonk & Hossenfelder GmbH und Ginkgo Management Consulting (Hrsg): : Lünendonk. Online im Internet: https://www.ginkgo-analytics.com/wp-content/uploads/2019/07/L%C3%BCnendonk_Ginkgo_Studie_K%C3%BCnstliche_Intelligenz_f2019.pdf.
- Nadikattu, R.R. (2020):** Research on Data Science, Data Analytics and Big Data In: *SSRN Electronic Journal*. Online im Internet: <https://www.ssrn.com/abstract=3622844>, Stand: 09.12.2021, DOI: 10.2139/ssrn.3622844.
- Nyhuis, P. (2008):** Produktionskennlinien – Grundlagen und Anwendungsmöglichkeiten In: Nyhuis, P. (Hrsg): Beiträge zu einer Theorie der Logistik. Berlin, Heidelberg: Springer Berlin Heidelberg, 185–218. Online im Internet: <http://link.springer.com/10.1007/978-3-540-75642-2>, Stand: 09.12.2021, DOI: 10.1007/978-3-540-75642-2.
- Nyhuis, P./Mayer, J./Kuprat, T. (2014):** Die Bedeutung von Industrie 4.0 als Enabler für logistische Modelle In: Kersten, W./Koller, H. und Lödding, H. (Hrsg): Industrie 4.0 Wie intelligente Vernetzung und kognitive Systeme unsere Arbeit verändern. Berlin: GITO mbH, 79–100. Online im Internet: https://www.industrie-management.de/sites/industrie-management.de/files/sonderdrucke/loedding_Industrie-4-0.pdf.
- Otte, R./Wippermann, B./Otte, V. (2020):** Von Data Mining bis Big Data: Handbuch für die industrielle Praxis München: Carl Hanser Verlag GmbH & Co. KG. Online im Internet: <https://www.hanser-elibrary.com/doi/book/10.3139/9783446457171>, Stand: 08.12.2021, DOI: 10.3139/9783446457171.
- Papp, S./Weidinger, W./Meir-Huber, M./Tremel, T./Danis, M. (2019):** AI in verschiedenen Branchen In: Papp, S./Weidinger, W./Meir-Huber, M./Ortner, B. et al. (Hrsg): Handbuch Data Science: mit Datenanalyse und Machine Learning Wert aus Daten generieren. München: Hanser, 231–278. Online im Internet: <https://www.hanser-elibrary.com/doi/book/10.3139/9783446459755>.
- Plaue, M. (2021):** Data Science: Grundlagen, Statistik und maschinelles Lernen Berlin, Heidelberg: Springer Berlin Heidelberg. Online im Internet: <https://link.springer.com/10.1007/978-3-662-63489-9>, Stand: 24.11.2021, DOI: 10.1007/978-3-662-63489-9.
- Quix, C. (2021):** Big-Data-Technologien In: Frick, D./Gadatsch, A./Kaufmann, J./Lankes, B. et al. (Hrsg): Data Science: Konzepte, Erfahrungen, Fallstudien und Praxis. Wiesbaden: Springer Fachmedien Wiesbaden, 133–148. Online im Internet: <https://link.springer.com/10.1007/978-3-658-33403-1>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-33403-1.
- Raychaudhuri, S. (2008):** Introduction to Monte Carlo Simulation In: Mason, S.J./Hill, R.R./Mönch, L./Rose, O. et al. (Hrsg): 2008 Winter Simulation Conference. Miami, FL, USA: IEEE, 91–100. Online im Internet: <https://ieeexplore.ieee.org/document/4736059/>, Stand: 28.01.2022, DOI: 10.1109/WSC.2008.4736059.

- Runkler, T.A. (2015):** Data Mining, 2 Wiesbaden: Springer Fachmedien Wiesbaden. Online im Internet: <http://link.springer.com/10.1007/978-3-8348-2171-3>, Stand: 08.12.2021, DOI: 10.1007/978-3-8348-2171-3.
- Schöning, H./Dorchain, M. (2014):** Data Mining und Analyse In: Bauernhansl, T./ten Hompel, M. und Vogel-Heuser, B. (Hrsg): Industrie 4.0 in Produktion, Automatisierung und Logistik. Wiesbaden: Springer Fachmedien Wiesbaden, 543–554. Online im Internet: <http://link.springer.com/10.1007/978-3-658-04682-8>, Stand: 16.01.2022, DOI: 10.1007/978-3-658-04682-8.
- Schuh, G./Brandenburg, U./Cuber, S. (2012a):** Aufgaben In: Schuh, G. und Stich, V. (Hrsg): Produktionsplanung und -steuerung 1. Berlin, Heidelberg: Springer Berlin Heidelberg, 29–81. Online im Internet: <http://link.springer.com/10.1007/978-3-642-25423-9>, Stand: 24.11.2021, DOI: 10.1007/978-3-642-25423-9.
- Schuh, G./Brosze, T./Brandenbrug Ulrich, S. (2012b):** Aachener PPS-Modell In: Schuh, G. und Stich, V. (Hrsg): Produktionsplanung und -steuerung 1. Berlin, Heidelberg: Springer Berlin Heidelberg, 4, 11–28. Online im Internet: <http://link.springer.com/10.1007/978-3-642-25423-9>, Stand: 24.11.2021, DOI: 10.1007/978-3-642-25423-9.
- Schuh, G./Brosze, T./Meier, C. (2012c):** Gestaltungsaufgaben in der PPS In: Schuh, G. und Stich, V. (Hrsg): Produktionsplanung und -steuerung 1. Berlin, Heidelberg: Springer Berlin Heidelberg, 4, 297–305. Online im Internet: <http://link.springer.com/10.1007/978-3-642-25423-9>, Stand: 24.11.2021, DOI: 10.1007/978-3-642-25423-9.
- Schuh, G./Stich, V./Runge, S. (2012d):** Einführung In: Schuh, G. und Stich, V. (Hrsg): Produktionsplanung und -steuerung 1. Berlin, Heidelberg: Springer Berlin Heidelberg, 4, 3–10. Online im Internet: <http://link.springer.com/10.1007/978-3-642-25423-9>, Stand: 24.11.2021, DOI: 10.1007/978-3-642-25423-9.
- Schuh, G./Stich, V./Schmidt, C. (2008):** Produktionsplanung und -steuerung in Logistiknetzwerken In: Nyhuis, P. (Hrsg): Beiträge zu einer Theorie der Logistik. Berlin, Heidelberg: Springer Berlin Heidelberg, 249–274. Online im Internet: <http://link.springer.com/10.1007/978-3-540-75642-2>, Stand: 09.12.2021, DOI: 10.1007/978-3-540-75642-2.
- Shao, G./Shin, S.-J./Jain, S. (2014):** Data Analytics Using Simulation for Smart Manufacturing In: Proceedings of the Winter Simulation Conference 2014. Savannah, GA, USA: IEEE, 2192–2203. Online im Internet: <http://ieeexplore.ieee.org/document/7020063/>, Stand: 28.01.2022, DOI: 10.1109/WSC.2014.7020063.
- Wrona, T./Reinecke, P. (2019):** Wie strategisch sind Algorithmen? Die Rolle von Big Data und Analytics im Rahmen strategischer Entscheidungsprozesse In: Schröder, M. und Wegner, K. (Hrsg): Logistik im Wandel der Zeit – Von der Produktionssteuerung zu vernetzten Supply Chains: Festschrift für Wolfgang Kersten zum 60. Geburtstag. Wiesbaden: Springer Fachmedien Wiesbaden, 443–466. Online im Internet: <http://link.springer.com/10.1007/978-3-658-25412-4>, Stand: 08.12.2021, DOI: 10.1007/978-3-658-25412-4.

Zeisel, S. (2020): Big Data und Data Science in der strategischen Beschaffung: Grundlagen – Voraussetzungen – Anwendungschancen Wiesbaden: Springer Fachmedien Wiesbaden. Online im Internet: <http://link.springer.com/10.1007/978-3-658-31202-2>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-31202-2.

Zgrzebski, W. (2021): Grußwort: Data Science – Weiterbildung für die Zukunft In: Frick, D./Gadatsch, A./Kaufmann, J./Lankes, B. et al. (Hrsg): Data Science: Konzepte, Erfahrungen, Fallstudien und Praxis. Wiesbaden: Springer Fachmedien Wiesbaden, XI. Online im Internet: <https://link.springer.com/10.1007/978-3-658-33403-1>, Stand: 24.11.2021, DOI: 10.1007/978-3-658-33403-1.

Eidesstattliche Erklärung und Einverständnis zur Veröffentlichung

Eidesstattliche Erklärung des Autors

Ich versichere, dass ich die vorliegende Arbeit ohne fremde Hilfe selbständig verfasst und nur die angegebenen Quellen und Hilfsmittel benutzt habe. Wörtlich oder dem Sinn nach aus anderen Werken entnommene Stellen sind unter Angabe der Quelle kenntlich gemacht.

Hamburg, den

(Unterschrift der/des Studierenden)

Einverständniserklärung zur Online-Veröffentlichung einer Abschlussarbeit auf dem Dokumentenserver der HAW Hamburg

Autor/in (Name, Vorname): Busch, Dennis

Titel der Abschlussarbeit: „Bewertung von Data Science und Analytics Methoden in der Produktionsplanung eines Industrieunternehmens zur Verbesserung der Planungsqualität“

Art der Abschlussarbeit (Bachelor-, Master- oder Diplomarbeit): Bachelorarbeit

Fakultät: Wirtschaft und Soziales

Department: Wirtschaft

1. Ich übertrage der Hochschule für Angewandte Wissenschaften (HAW) Hamburg – vertreten durch den Hochschulinformations- und Bibliotheksservice (HIBS) der HAW Hamburg – das nichtausschließliche Recht, die oben genannte Abschlussarbeit elektronisch zu speichern, ggf. in andere Formate zu konvertieren, zu vervielfältigen, auf dem Server der HAW Hamburg dauerhaft öffentlich zugänglich zu machen und über das Internet zu verbreiten.
2. Ich bin mir bewusst, dass mit Veröffentlichung meiner Abschlussarbeit auf den Servern der HAW Hamburg eine Verpflichtung der HAW Hamburg besteht, die Arbeiten nach dem Pflichtabgabegesetz an die Deutsche Nationalbibliothek sowie die Staats- und Universitätsbibliothek Hamburg zu liefern.

3. Der Dokumentenserver wird von der HAW Hamburg betrieben. Die HAW Hamburg behält sich vor, diese Dienstleistung ggf. an Dritte zu vergeben.
4. Ich wurde darauf hingewiesen, dass die Veröffentlichung der Arbeit auf einem Server der HAW Hamburg zur Erschwerung oder Verhinderung anderweitiger Veröffentlichungen führen kann.
5. Ich versichere, dass ich alleinige/r Inhaber/in sämtlicher Rechte an der oben genannten Arbeit bin und dass durch die Veröffentlichung nicht in Rechte Dritter eingegriffen wird oder geltende Gesetze verletzt werden. Dies schließt die in der vorliegenden Arbeit enthaltenen Abbildungen wie z.B. Fotos oder Grafiken ein.
6. Ich versichere, dass meine Abschlussarbeit keine personenbezogenen Daten Dritter, die dem Datenschutz unterliegen, enthält bzw. eine ausdrückliche schriftliche Einwilligung zur Veröffentlichung vorliegt.
7. Ich versichere, dass die abgegebene Version der Abschlussarbeit mit der genehmigten Originalfassung übereinstimmt. Ausgenommen hiervon sind die Teile einer Publikation, die dem Datenschutz unterliegen.
8. Der/die Autor/in verpflichtet sich, die HAW Hamburg von allen Ansprüchen, die Dritte auf Grund ihnen zustehender Urheber- oder sonstiger Schutzrechte gegen die HAW Hamburg erheben, freizustellen.
9. Wird die HAW Hamburg unmittelbar von einem Dritten in Anspruch genommen, ist der/die Autor/in verpflichtet, der HAW Hamburg unverzüglich alle zur Abwehr von Ansprüchen erforderlichen Informationen und Beweismittel zu übergeben.
10. Die HAW Hamburg ist berechtigt, den Zugriff auf die oben genannte Arbeit ganz oder teilweise zu sperren, soweit konkrete Anhaltspunkte dafür bestehen, dass die Arbeit gegen gesetzliche Vorschriften verstößt oder wenn die Verletzung von Rechten Dritter geltend gemacht wird, die nicht offensichtlich unbegründet ist.
11. Ich wurde darauf hingewiesen, dass die HAW Hamburg nicht für die missbräuchliche Verwendung von Inhalten durch Dritte haftet. Insbesondere ist mir bewusst, dass ich für die Anmeldung von Schutzrechten allein verantwortlich bin.
12. Sollte ich meine Arbeit nicht von mich betreffenden personenbezogenen Daten (z.B. Datum der Abschlussprüfung, Lebenslauf) bereinigt haben, bin ich mit der Speicherung und Veröffentlichung dieser Daten einverstanden. Ich wurde darauf hingewiesen, dass die bibliographischen Daten und Abstracts der Arbeit über verschiedene Kataloge, Datenbanken und Suchmaschinen im Internet zugänglich gemacht werden.

13. Der/die Autor/in hat das Recht, die oben genannte Arbeit auch anderweitig verfügbar zu machen und zu verbreiten.
14. Die Arbeit kann auf Verlangen des/r Autors/in von den Servern der HAW Hamburg gelöscht werden. Ich bin mir bewusst, dass die Löschung der Arbeit von den Servern der HAW Hamburg nicht die Abgabe an die Deutsche Nationalbibliothek sowie die Staats- und Universitätsbibliothek Hamburg betrifft und die Arbeit hier weiterhin öffentlich zugänglich ist.

Ort, Datum, Unterschrift:

Erklärung des/r wissenschaftlichen Betreuers/in

Hiermit wird bestätigt, dass die oben genannte Abschlussarbeit den Veröffentlichungsrichtlinien des Departments entspricht. Der Veröffentlichung der Abschlussarbeit auf dem Dokumentenserver der HAW Hamburg wird zugestimmt.

Wissenschaftliche/r Betreuer/in (Name, Vorname):

Ort, Datum, Unterschrift des/r Betreuers/in: