

*Julian L. Weller*

***Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion***

***Specification and design framework for prescriptive analytics solutions in manufacturing***

**Bibliografische Information Der Deutschen Bibliothek**

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

© Universität Paderborn – Paderborn – 2026

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

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

Satz und Gestaltung: Julian Lennart Weller

## Geleitwort

Advanced Systems Engineering beschreibt die neue Perspektive auf die Entwicklung und das Betreiben von intelligenten technischen Systemen. Das ist die verbindende Leitidee unserer Forschungsarbeit. In der gleichnamigen Fachgruppe am HEINZ NIXDORF INSTITUT der Universität Paderborn sowie am Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM arbeiten wir an dieser Leitidee. Unser generelles Ziel ist die Steigerung der Innovationskraft von Industrieunternehmen. Zentrale Schwerpunkte der Forschung an den beiden Instituten sind die strategische Planung und das Systems Engineering.

Advanced Systems umfassen nicht nur moderne cyber-physische Produkte, sondern auch die heutigen Produktionssysteme. Diese Systeme generieren enorme Datenmengen und bieten gleichzeitig vielfältige Möglichkeiten zur datengetriebenen Entscheidungsunterstützung. Mit der zunehmenden Komplexität der Entscheidungssituationen geht jedoch auch die Herausforderung einher, Prescriptive Analytics Lösungen systematisch zu planen, zu konzipieren und in bestehende Strukturen zu integrieren. Eine methodische Unterstützung hierfür – eine Spezifikationstechnik, die eine gemeinsame Sprache zwischen Produktion, IT und Data Science schafft – fehlt bislang.

Vor diesem Hintergrund hat Herr Weller eine *Spezifikationstechnik für Prescriptive-Analytics-Lösungen in der Produktion* erarbeitet. Diese versetzt produzierende Unternehmen in die Lage, die Potenziale von Prescriptive Analytics systematisch zu erschließen. Die Spezifikationstechnik führt den Anwender dabei von der Identifikation über die Konzeption bis hin zur Integration von Prescriptive Analytics Use Cases und stellt hierfür geeignete Vorgehensmodelle und Hilfsmittel bereit. Ein ergänzendes Modellierungskonzept gewährleistet, dass die erarbeiteten Lösungen konsistent beschrieben und nahtlos in bestehende Produktions- und IT-Landschaften eingebettet werden können.

Mit seiner Arbeit liefert Herr Weller einen substanziellen Beitrag zur internationalen Forschung im Bereich Industrial Data Science und Enterprise Architecture Management. Die Dissertation verbindet wissenschaftliche Rigorosität mit einer klar nachgewiesenen Praxisrelevanz. Durch die fundierte Verknüpfung bewährter Methoden mit international anerkannten Forschungsansätzen wird Herr Weller die Arbeit unseres Instituts nachhaltig bereichern.



# **Spezifikationstechnik für Prescriptive Analytics**

## **Lösungen in der Produktion**

zur Erlangung des akademischen Grades eines  
DOKTORS DER INGENIEURWISSENSCHAFTEN (Dr.-Ing.)  
der Fakultät für Elektrotechnik, Informatik und Mathematik  
der Universität Paderborn

genehmigte  
DISSERTATION

von  
M. Sc. Julian Lennart Weller  
aus Paderborn

Referent: Prof. Dr.-Ing. Roman Dumitrescu  
Korreferent: Prof. Dr.-Ing. Jörg Franke



## **Vorwort**

Die vorliegende Dissertation ist im Rahmen meiner dreijährigen Forschungstätigkeit am FRAUNHOFER-INSTITUT FÜR ENTWURFSTECHNIK MECHATRONIK IEM entstanden. Thematisch verortet im Bereich der digitalen Transformation, basiert sie auf Erkenntnissen aus Forschungs- und Industrieprojekten.

Zuallererst danke ich Herrn Prof. Dr.-Ing. Roman Dumitrescu für die hervorragende Betreuung und die konstruktive Zusammenarbeit. Durch gezielte Impulse und kritische Rückfragen hast du mir geholfen, den roten Faden meiner Arbeit nicht aus den Augen zu verlieren. Das von dir geprägte Arbeitsumfeld hat meine fachliche wie auch persönliche Weiterentwicklung maßgeblich gefördert.

Ebenso danke ich Herrn Prof. Dr.-Ing. Sebastian von Enzberg. Als mein damaliger Gruppenleiter hast du den Grundstein für meine wissenschaftliche Arbeitsweise gelegt. Den Kolleginnen und Kollegen am FRAUNHOFER IEM danke ich für die gemeinsame Zeit – für anspruchsvolle Projekte, prägende Erlebnisse und vor allem für den Humor, der nie zu kurz kam. Hervorheben möchte ich Dr.-Ing. Arno Kühn: Unsere fachlichen Diskussionen haben die inhaltliche Ausrichtung meiner Dissertation entscheidend mitgeformt. Mehr noch hat dein Einsatz für eine kollegiale aber stets leistungsorientierte Zusammenarbeit das gesamte Team geprägt. Meinen Bürokollegen Jonathan Brock und Tim Heuwinkel danke ich für den gegenseitigen Ansporn und die inspirierenden Gespräche. Mark Henkenjohann und Finn Buttgerit verdanke ich, dass wir uns in unseren wöchentlichen Dissertations-Sprint-Sessions gemeinsam motiviert haben – dieses Format war ein entscheidender Faktor für meinen Fortschritt. Victoria Fischer, Lars Hilgenkamp und Leah Gärner gilt mein Dank für das sorgfältige Korrekturlesen. Sabine Illigen, Alexandra Dutschke und Miriam Polotzek danke ich für die zuverlässige organisatorische Begleitung vom ersten Tag an.

Nicht zuletzt danke ich meiner Familie. Meinen Eltern Dorothee und Christian dafür, dass sie mir ein stabiles Fundament gegeben haben. Meiner Freundin Camila, die mich gerade in der intensiven Schlussphase mit Zuversicht, Geduld und einem offenen Ohr begleitet hat.

Paderborn, im Februar 2026

*Julian L. Weller*



## Liste der Vorveröffentlichungen

- [WRE+23] WELLER, J.; ROESMANN, D.; EGGERT, S.; ENZBERG, S. VON; GRÄBLER, I.; DUMITRESCU, R.: Identification and prediction of standard times in machining for precision steel tubes through the usage of data analytics. *Procedia CIRP*, 33rd CIRP Design Conference, 2023
- [WML+23] WELLER, J.; MIGENDA, N.; LIU, R.; WEGEL, A.; ENZBERG, S. VON; KOHLHASE, M.; SCHENK, W.; DUMITRESCU, R.: Towards a systematic approach for Prescriptive Analytics Use Cases in Smart Factories. *ML4CPS - Machine Learning for cyber physical systems*, 2023
- [WMW+23] WELLER, J.; MIGENDA, N.; WEGEL, A.; KOHLHASE, M.; SCHENK, W.; DUMITRESCU, R.: Conceptual Framework for Prescriptive Analytics based on decision Theory. *IEEE ADACIS - International Conference on Advances in Data-driven Analytics and Intelligent Systems*, 2023
- [WME+24] WELLER, J.; MIGENDA, N.; ENZBERG, S. VON; KOHLHASE, M.; SCHENK, W.; DUMITRESCU, R.: Design decisions for integrating Prescriptive Analytics Use Cases into Smart Factories. *Procedia CIRP*, 34th CIRP Design Conference, 2024, S. 424–429
- [WMK+24] WELLER, J.; MIGENDA, N.; KÜHN, A.; DUMITRESCU, R.: Prescriptive Analytics Data Canvas: Strategic Planning for Prescriptive Analytics in Smart Factories. *CPSL - Conference on Production Systems and Logistics 2024 (Hawaii, Honolulu)*, Hannover publish-Ing, 2024
- [EWB+24] ENZBERG, S. VON; WELLER, J.; BROCK, J.; MERKELBACH, S.; PANZNER, M.; LICK, J.; KÜHN, A.; DUMITRESCU, R.: On the Current State of Industrial Data Science: Challenges, Best Practices, and Future Directions. *Procedia CIRP*, *CIRP CMS (130)*, 2024, S. 1454–1461
- [NMW+24] NIEDERHAUS, M.; MIGENDA, N.; WELLER, J.; SCHENCK, W.; KOHLHASE, M.: Technical Readiness of Prescriptive Analytics Platforms: A Survey. *35th FRUCT conference - Open Innovations Association FRUCT*, 2024, S. 509–519
- [WMN+24] WELLER, J.; MIGENDA, N.; NAIK, Y.; HEUWINKEL, T.; KÜHN, A.; KOHLHASE, M.; SCHENCK, W.; DUMITRESCU, R.: Reference Architecture for the Integration of Prescriptive Analytics Use Cases in Smart Factories. *Mathematics (MDPI) - Special Issue for Selected Papers From the 2023 IEEE International Conference on Advances in Data-Driven Analytics and Intelligent Systems*, 2024, (12)17, 2024, S. 2663
- [WNG+25] WELLER, J.; NALAVADE, S.; GMELCH, O.; MIGENDA, N.; HEUWINKEL, T.; DUMITRESCU, R.: Advanced Analytics in Smart Factories: Towards an actionable Taxonomy for Prescriptive Analytics Use Cases. *CIRP CMS 2025*, 2025
- [WBL+25] WELLER, J.; BROCK, J.; LICK, J.; HEUWINKEL, T.; HARTMANN, S.; GABRIEL, S.; KÜHN, A.; ENZBERG, S. VON; DUMITRESCU, R.: Advanced Analytics Capability Map for Smart Factories: Supporting the Planning, Design, Management and Operations of Advanced Analytics Use Cases. *CIRP CMS 2025*, 2025
- [NMW+25] NIEDERHAUS, M.; MIGENDA, N.; WELLER, J.; KOHLHASE, M.; SCHENCK, W.: Integrating Graph Retrieval-Augmented Generation into Prescriptive Analytics Platforms. *MDPI - Big Data and Cognitive Computing*, 2025
- [WD25] WELLER, J.; DUMITRESCU, R.: Decision Driven Analytics in Smart Factories: Enterprise Architecture Framework for Use Case Specification and Engineering (FUSE). *MDPI Electronics - Special Issue - Applications of Artificial Intelligence in Intelligent Manufacturing (under review)*, 2025

**Liste aller Veröffentlichungen im Rahmen der Tätigkeit am Fraunhofer IEM**

- [EWP+24] ENZBERG, S. VON; WELLER, J.; PÖHLER, P.; KÜHN, A.; RÖMER, M.; DUMITRESCU, R.: Künstliche Intelligenz in der Produktionsplanung und -steuerung: Potenziale und Anwendungsreife. Zeitschrift für wirtschaftlichen Fabrikbetrieb, 2024
- [LWB+24] LICK, J.; WELLER, J.; BROCK, J.; PATHAK, S.; DISSELKAMP, J.-P.; KÜHN, A.; DUMITRESCU, R.: Guiding The Transformation To A Digital Factory Twin: Towards An Enterprise-Architecture-Management-based Approach With The Help Of A Capability Map. Procedia CIRP, (130), 2024, S. 736–742
- [HBH+25] HANKE, F.; BITA, I. M.; HEIBEN, O. VON; WELLER, J.; ASCHOT, H.; ROMAN, D.: AI-augmented systems engineering: conceptual application of retrieval-augmented generation for model-based systems engineering graph. Proceedings of the Design Society, (5), 2025, S. 439–448
- [HWG+26] HEUWINKEL, T.; WELLER, J.; GABRIEL, S.; KÜRPICK, C.; DUMITRESCU, R.: Still no Smart Service? A Review of Technical Barriers to Smart Service Adoption in the GenAI Era – CIRP Design 2026, Tokio. Procedia CIRP, 2026 (under review)

## **Zusammenfassung**

Produzierende Unternehmen durchlaufen aufgrund eines zunehmenden Maßes an Digitalisierung eine Transformation hin zum datengetriebenen Unternehmen. Die inhärente Komplexität der Produktion stellt dabei zunehmend hohe Anforderungen an Entscheidungsträger. Der Einsatz von Prescriptive Analytics verspricht insbesondere im produktionsnahen Bereich große Potenziale zur Rationalisierung und Prozessverbesserung in Entscheidungsabläufen. Prescriptive Analytics wird genutzt, um direkt die nötige Aktion zur Entscheidung zu empfehlen und so einen maximalen Grad an Entscheidungsunterstützung bereitzustellen. Jedoch wird Prescriptive Analytics bisher nur in Leuchtturmprojekten umgesetzt und kommt nicht flächendeckend zum Einsatz. Eine elementare Herausforderung stellt eine fehlende Unterstützung bei der Planung, Konzeption und Integration der beschriebenen Use Cases dar.

Ziel der vorliegenden Spezifikationstechnik ist die Unterstützung bei der Planung, Konzeption und Integration von Prescriptive Analytics Lösungen in der Produktion. Ein Vorgehensmodell dient der Strukturierung des gesamtheitlichen Vorhabens. Zur Umsetzung der einzelnen Phasen wird ein Modellierungskonzept mitsamt Artefakten zur Unterstützung des Ausfüllens der vorgeschlagenen Partialmodelle in sachlogischer Reihenfolge bereitgestellt. Exemplarische Artefakte zur Unterstützung sind eine Referenzarchitektur für die Integration von Prescriptive Analytics Use Cases in die Produktion sowie eine generische Capability Map zur Planung der Verankerung der benötigten organisatorischen Fähigkeiten. Die Evaluation der Spezifikationstechnik erfolgt anhand eines Anwendungsbeispiels aus der produzierenden Industrie.

## **Summary**

Due to an increasing degree of digitalization, manufacturing companies are undergoing a transformation towards becoming data-driven companies. However, the inherent complexity of manufacturing is placing increasingly high demands on decision-makers. The use of prescriptive analytics promises great potential for rationalization and process improvement in decision-making workflows, particularly in production-related areas. Prescriptive analytics is used to directly recommend the necessary action for the decision and thus provide a maximum degree of decision support. Nevertheless, prescriptive analytics has so far only been implemented in lighthouse projects and is not used across the board. A fundamental challenge is the lack of support in the planning, conceptualization and integration of the described use cases.

The aim of this specification technique is to support the planning, design and integration of prescriptive analytics solutions in manufacturing. A process model is used to structure the overall project. To implement the individual phases, a modelling concept including artefacts is provided to support the filling of the proposed partial models in a logical sequence. Exemplary artifacts are a reference architecture for the integration of prescriptive analytics use cases in production and a generic capability map for planning the anchoring of the required organizational capabilities. The evaluation of the specification technique is based on an application example from the manufacturing industry.



## Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion

	Inhaltsverzeichnis	Seite
<b>1</b>	<b>Einleitung .....</b>	<b>1</b>
1.1	Problematik.....	1
1.2	Zielsetzung der Ausarbeitung .....	3
1.3	Vorgehensweise und Forschungsmethode .....	3
1.4	Struktur der Ausarbeitung.....	6
<b>2</b>	<b>Problemanalyse .....</b>	<b>7</b>
2.1	Begriffsdefinitionen und Einordnung der Ausarbeitung.....	7
2.1.1	Spezifikationstechnik .....	7
2.1.2	Produktion und Industrie 4.0.....	9
2.1.3	Prescriptive Analytics .....	11
2.1.4	Analytics Use Cases und Lösungen .....	14
2.2	Produktion auf dem Weg hin zur Vision der Industrie 4.0.....	14
2.2.1	Industrie 4.0 Use Cases .....	15
2.2.2	Industrie 4.0 Reifegradstufen.....	16
2.2.3	Industrie 4.0 Daten-Infrastruktur .....	18
2.2.4	Status Quo und Herausforderungen in der Umsetzung .....	20
2.3	Industrial Data Science für die Produktion.....	21
2.3.1	Industrial Data Science Use Case Strukturierung.....	21
2.3.2	Analytics Use Cases.....	22
2.3.3	Analytics Komponenten und Daten-Infrastruktur .....	24
2.3.4	Rollen in der Industrial Data Science.....	27
2.4	Prescriptive Analytics in der Produktion .....	28
2.4.1	Prescriptive Analytics Use Cases .....	29
2.4.2	Prescriptive Analytics Komponenten .....	32
2.4.3	Prescriptive Analytics Daten-Infrastruktur.....	34
2.5	Entwicklung von Prescriptive Analytics Use Cases .....	36
2.5.1	Strategiekonforme Entwicklung von Analytics Use Cases.....	37
2.5.2	Identifikation von Analytics Use Cases für die Produktion .....	39
2.5.3	Planung von Analytics Use Cases.....	40
2.5.4	Enterprise Architecture Management für die Produktion .....	42
2.5.5	Konzeption von Analytics Use Cases .....	43
2.5.6	Implementierung von Analytics Use Cases .....	45

2.6	Problemabgrenzung .....	47
2.7	Anforderungen an die Spezifikationstechnik.....	51
<b>3</b>	<b>Stand der Technik .....</b>	<b>55</b>
3.1	Vorgehensmodelle zur Entwicklung von Prescriptive Analytics Use Cases .....	55
3.1.1	Industrie 4.0 Einführungsstrategie nach MERZ .....	56
3.1.2	Rollout-Planung für Smart Factory Use Cases nach BUDDE ET AL.....	57
3.1.3	Strategische Planung: Mensch-KI-Kollaboration nach GABRIEL ET AL. ....	59
3.1.4	Transfer von Predictive Analytics nach VON ENZBERG ET AL. ....	60
3.2	Unterstützung der Konzeption von Prescriptive Analytics Use Cases ..	61
3.2.1	Spezifikationstechnik für Engineering IT-Architekturen nach HEIHOFF-SCHWEDE.....	63
3.2.2	Analytics Canvas für die Entwicklung von Data Science Anwendungen nach KÜHN ET AL.....	64
3.2.3	Data Map zur Spezifikation von Datenflüssen in Produktionsumgebungen nach JOPPEN ET AL.....	66
3.2.4	Business to Analytics Canvas nach PANZNER ET AL. ....	68
3.2.5	PAISE: Systems Engineering für KI-Systeme nach HASTEROK ET AL. ....	70
3.3	Gestaltungswissen für Prescriptive Analytics .....	72
3.3.1	Konstituierende Elemente von Prescriptive Analytics Systemen nach WISSUCHEK UND TSCHECH .....	72
3.3.2	Archetypen von Prescriptive Analytics Systemen nach WISSUCHEK UND TSCHECH .....	74
3.3.3	Prescriptive Analytics Plattform-Überblick nach NIEDERHAUS ET AL. ....	75
3.3.4	Prescriptive Analytics Referenzarchitektur-Überblick .....	77
3.4	Bewertung und Handlungsbedarf .....	80
<b>4</b>	<b>Spezifikationstechnik.....</b>	<b>85</b>
4.1	Bestandteile der Spezifikationstechnik im Überblick.....	85
4.2	Strukturierung von Prescriptive Analytics in der Produktion .....	87
4.2.1	Mechanismen zur Analytics Use Case Identifikation .....	87
4.2.2	Taxonomie für Prescriptive Analytics Use Cases .....	89
4.2.3	Design Prinzipien für Prescriptive Analytics Use Cases .....	90
4.3	Vorgehensmodell.....	91

---

4.3.1	Das Vorgehensmodell im Überblick.....	92
4.3.2	Einordnung des Vorgehensmodells.....	93
4.3.3	Das Vorgehensmodell im Detail .....	94
4.3.3.1	Phase 1: Strategische Planung der Use Cases.....	96
4.3.3.2	Phase 2: Konzeption der ausgewählten Use Cases..	97
4.3.3.3	Phase 3: Prüfen der Integrierbarkeit.....	98
4.3.3.4	Phase 4: Aufbereitung zur Umsetzung .....	98
4.4	Modellierungskonzept.....	99
4.4.1	Einordnung des Modellierungskonzepts .....	100
4.4.2	Zugrundeliegende Perspektiven .....	102
4.4.3	Partialmodelle.....	103
4.4.4	Spezialisierung des ArchiMate Metamodells .....	105
4.4.5	Vernetzung der Partialmodelle .....	106
4.4.6	Verwendung der Partialmodelle.....	108
4.5	Artefakte zur Unterstützung .....	109
4.5.1	Einordnung der Artefakte.....	109
4.5.2	Prescriptive Analytics Use Case Transformation Canvas.....	112
4.5.3	Generische Prescriptive Analytics Capability Map.....	113
4.5.4	Prescriptive Analytics Data Canvas .....	115
4.5.5	Referenzarchitektur zur Integration von Prescriptive Analytics	117
4.5.6	Referenzpipeline für Prescriptive Analytics Use Cases .....	121
4.6	Werkzeugunterstützung.....	123
4.6.1	Einordnung der Werkzeugunterstützung .....	123
4.6.2	Analysefragen zur Synergie- und Schnittstellenbetrachtung ...	125
4.6.3	Unterstützung durch Workshopkarten .....	127
<b>5</b>	<b>Demonstration und Evaluation der Spezifikationstechnik.....</b>	<b>129</b>
5.1	Demonstration anhand eines Anwendungsbeispiels .....	129
5.1.1	Strategische Planung der Use Cases.....	130
5.1.2	Konzeption der ausgewählten Use Cases.....	136
5.1.3	Prüfen der Integrierbarkeit.....	139
5.1.4	Detaillierung zur Umsetzung.....	144
5.2	Evaluation.....	146
5.2.1	Bewertung der Erfüllung der erhobenen Anforderungen .....	147
5.2.2	Evaluationsinterviews zu Nutzbarkeitsaspekten .....	150
5.3	Diskussion der Ergebnisse .....	153
5.3.1	Beitrag der Spezifikationstechnik.....	153
5.3.2	Einordnung in das Advanced Systems Engineering .....	156
5.3.3	Integrierbarkeit und Übertragbarkeit.....	157
<b>6</b>	<b>Zusammenfassung und Ausblick .....</b>	<b>161</b>

## Anhang

<b>A1</b>	<b>Ergänzungen zur Problemanalyse .....</b>	<b>A-3</b>
A1.1	Künstliche Intelligenz für Industrial Data Science .....	A-3
A1.2	Aktionen und Entscheidungen .....	A-4
A1.3	Schnittmengen und angrenzende relevante Konzepte .....	A-5
A1.4	Daten für Industrial Data Science .....	A-8
A1.5	Sammlung von Prescriptive Analytics Use Cases .....	A-10
<b>A2</b>	<b>Ergänzungen zur Spezifikationstechnik .....</b>	<b>A-11</b>
A2.1	Rahmenwerk für Industrial Data Science .....	A-11
A2.2	Design Prinzipien für Prescriptive Analytics Use Cases .....	A-12
A2.3	Subkategorien der Taxonomie für Prescriptive Analytics Use Cases .....	A-13
A2.4	Meta-Recommendier Ansatz für Prescriptive Analytics Use Cases .....	A-16
A2.5	Mapping von Concerns und Partialmodellen .....	A-17
A2.6	Ergänzende Informationen zum Metamodell .....	A-19
A2.7	Vergleich der Spezialisierung mit etablierten Metamodellen .....	A-23
A2.8	Blueprints und One Pager für das Partialmodellkonzept .....	A-28
A2.9	Use Case Transformation Canvas mit Leitfragen .....	A-35
A2.10	Detaillierte Prescriptive Analytics Capability Map .....	A-36
A2.11	Beispielhafte Analysefragen für das Modell .....	A-48
<b>A3</b>	<b>Forschungsdesign der Spezifikationstechnik .....</b>	<b>A-49</b>
A3.1	Herleitung des übergeordneten Vorgehensmodells .....	A-49
A3.2	Herleitung des Modellierungskonzepts .....	A-55
A3.3	Forschungsvorgehen der Artefakte .....	A-56
<b>A4</b>	<b>Ergänzungen zur Demonstration und Evaluation der Spezifikationstechnik .....</b>	<b>A-67</b>
A4.1	Ausgefüllte Use Case Transformation Canvas .....	A-67
A4.2	Initial bewertete Capability Map .....	A-68
A4.3	Detailliertes Use Case Portfolio .....	A-69
A4.4	Detaillierte Data Map .....	A-71
A4.5	Detaillierte Analytics Canvas .....	A-72
A4.6	Detaillierte Applikationsarchitektur .....	A-73
A4.7	Datenkatalog der IoT Factory .....	A-74
A4.8	Datenobjektbasierte Roadmap .....	A-75

---

A4.9 Detaillierte Pipeline .....	A-77
A4.10 Ergebnisse der Nutzerevaluation .....	A-80



# 1 Einleitung

Die vorliegende Ausarbeitung entstand im Rahmen der anwendungsorientierten Forschung am FRAUNHOFER-INSTITUT FÜR ENTWURFSTECHNIK MECHATRONIK IEM. Sie basiert auf Ergebnissen des vom BUNDESMINISTERIUM FÜR BILDUNG UND FORSCHUNG geförderten Forschungsprojektes *VIP4PAPS*, dessen Hauptziel die Validierung einer Prescriptive Analytics Plattform ist. Im Zuge dieses Projektes wurden mehrere Prescriptive Analytics Lösungen entwickelt. Die Anwendung der Spezifikationstechnik erfolgte in der „IoT Factory Gütersloh“ des *CENTER FOR APPLIED DATA SCIENCE GÜTERSLOH*.

## 1.1 Problematik

**Produzierende Unternehmen** in Deutschland stehen vor großen Herausforderungen: Akuter Fachkräftemangel, zunehmender globaler Wettbewerb und der Wandel hin zu nachhaltiger Produktion prägen das aktuelle Spannungsfeld [HHS24, S. 11, Aue18, S. 8, FSZ21, S. 14]. Als mögliche Antwort auf diese Herausforderungen bieten neue Technologien Potenziale in Form von Rationalisierung, Effizienzsteigerung und Prozessverbesserungen [HHS24, McC24].

Der Begriff der **Industrie 4.0** fasst den Einsatz von neuen Technologien in der Produktion zusammen [HKS+22, S. 3]. Die Umsetzung der Vision der Industrie 4.0 führt zu einem steigenden Digitalisierungsgrad in produzierenden Unternehmen [WMH+18, RRH+24, S. 438]. Digitale Prozesse und Maschinen ermöglichen eine verstärkte Verfügbarkeit von Daten. Diese Daten sind aber noch nicht immer direkt zur gezielten Analyse verfügbar [WWS+24, S. 3]. Parallel dazu entwickelt sich die Technologie zur Generierung von Erkenntnissen aus diesen Daten (Data Analytics) stetig weiter [JCL+23, Per23-ol, HHS24, S. 10]. Die Akzeptanz für Data Analytics Lösungen und den Einsatz von Methoden der künstlichen Intelligenz wächst ebenfalls [GFG+24, S. 22, HHS24, S. 28].

Trotz verschiedener Hindernisse auf dem Weg zur Vision der Industrie 4.0 finden immer mehr fortschrittliche **Data Analytics** Lösungen Einzug in die Produktionsumgebung [GBW22, S. 33, WWS+24, S. 3]. Data Analytics spielt eine Schlüsselrolle bei der Optimierung der Produktion [RRH+24, S. 438]. Während Data Analytics Lösungen im nicht-industriellen Kontext bereits weit verbreitet sind, bleiben sie in der Produktion und im Maschinenbau oft auf einzelne Pilotprojekte und Insellösungen beschränkt [GBW22, WB23, HHS24, S. 32, KGK23, S. 149].

**Prescriptive Analytics** als Teil der Data Analytics beschreibt die Empfehlung von Handlungen oder Aktionen auf Basis einer (teil-)automatisierten Entscheidung [Cao18]. Bis zur Stufe der Predictive Analytics sind einzelne Lösungen in produzierenden Unternehmen bereits etabliert [GBW22, S. 12, HHS24, McC24]. Darauf aufbauend verspricht Prescriptive Analytics neben der Automatisierung von Entscheidungsprozessen auch eine größere Unabhängigkeit von einzelnen Entscheidern. Menschliche Fehler in Prozessen

können reduziert werden [LBA+20, S. 58, ZWD+21, S. 798, KGK23, S. 111]. Dadurch wird der Grundstein für autonome Prozesse und Systeme gelegt [BWS23, S. 337].

Ein **Beispiel für eine Prescriptive Analytics Lösung** aus dem Forschungsprojekt VIP4PAPS ist das Prescriptive Production Management. In diesem Prescriptive Analytics Use Case wird bei einem prädiktiv erkannten Störfall eines Anlagenteils das Bedienpersonal bei der Problemlösung unterstützt. Dies beginnt mit der unmittelbaren Assistenz zum Verhindern des Fehlers. Auswirkungen auf die Produktionsreihenfolge und das umliegende System werden geprüft und Empfehlungen zur Sicherstellung eines reibungslosen Ablaufes bereitgestellt.

GARTNER prognostiziert in seinem jährlich veröffentlichten Hype Cycle 2022, dass das **Technologiefeld Prescriptive Analytics** in den nächsten drei bis fünf Jahren sein volles Potential ausschöpfen wird [Gar22b]. Auch Unternehmen wie *BMW* führen dieses Technologiefeld in ihrem Trend Radar als eine der Top-Drei Technologien, auf die unmittelbar reagiert werden sollte [BMW22]. Durch den Fokus auf Entscheidungen gewinnen Aspekte wie die Quantifizierung von Entscheidungszielen, das Abbilden komplexer Systeme und die Annäherung von Unsicherheiten eine größere Rolle [LYH+19, S. 292, MKD23, S. 140, LBM22]. Jedoch steigt der Einsatz von Systemen zur Entscheidungsunterstützung stetig [HHS24, S. 28]. Allerdings spielen Prescriptive Analytics Use Cases in der Praxis bisher nur eine untergeordnete Rolle und der Einsatz liegt im deutschsprachigen Raum hinter dem internationalen Standard zurück [HHS24, S. 10].

Für die **Entwicklung von Data Analytics Use Cases** fehlt es oft zusätzlich an umfangreichem Wissen und Kapazitäten [KR22, S. 46]. Analytics Use Cases werden als Leuchtturmprojekte geplant und es mangelt nach wie vor an Unterstützung zur Skalierung der Lösungen in der Produktion [SvS+24, S. 180]. Dies liegt unter anderem an der fehlenden Transparenz des monetären Nutzens komplexerer Lösungen bei der **Planung** von Analytics Use Cases [Jop21, MVO21, WWS+24, S. 3, EWB+24]. Die geplanten Use Cases müssen für die Implementierung weiter konkretisiert werden. Der dafür verwendete Schritt der **Konzeption** ist ein bisher wenig beachtetes Thema zur Steigerung der Effizienz bei der Entwicklung von Analytics Use Cases [EWB+24]. Zusätzlich muss die **Integration** der zu realisierenden Lösungen in die bestehende heterogene IT-Landschaft und Organisationsstruktur in der Produktion sichergestellt werden [HHS24, S. 32, BHF+23, S. 6, EWB+24, WZ24, S. 39].

Darauf aufbauend erfordert die **Konzeption von Prescriptive Analytics Use Cases** ein effektives Komplexitätsmanagement [WZ24, S. 39, GFG+24, S. 22]. Dabei liegt die Komplexität in der Erweiterung der verwendeten Daten um die für die Präskription benötigten Aktionen. Zudem sind die Use Cases stärker vernetzt [WZ23, MKD23, LBA+20]. Um komplexe Prescriptive Analytics Use Cases zu realisieren, kommt der Konzeption eine große Bedeutung zu.

Zusammenfassend dient **Prescriptive Analytics** der Umsetzung automatisierter Handlungsempfehlungen im Rahmen der Vision von Industrie 4.0. Prescriptive Analytics Use

Cases bilden die Grundlage für autonome Systeme. Insbesondere in der Produktion können sie wertvolle Unterstützung bieten. Dennoch sind Prescriptive Analytics Lösungen bislang wenig in der Praxis etabliert. Einer der Hauptgründe dafür ist die **fehlende Unterstützung bei der ganzheitlichen Entwicklung** (Planung, Konzeption und Integration) der Prescriptive Analytics Lösungen.

## 1.2 Zielsetzung der Ausarbeitung

Um eine Unterstützung bei der Planung, Konzeption und Integration bereitzustellen, wird eine Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion entwickelt. Spezifikationstechniken können zur Analyse, Gestaltung und Bewertung von IT-Architekturen genutzt werden [Hei24, S. 7]. Sie befähigen verschiedene Akteure domänenübergreifend effizient zu kommunizieren [GN12, S. 8] und finden unter anderem in der Konzeption von intelligenten technischen Systemen aus dem Bereich der Mechatronik Anwendung (z. B. [Fra06, Sch18, Hei24]). Im Folgenden wird mit einer Spezifikationstechnik die Abstimmung der Beziehungen zwischen Sprache, Methode und Werkzeug mit dem Zweck der Architekturmodellierung beschrieben. Diese Abstimmung wird in der Ausarbeitung durch ein Vorgehensmodell, ein Modellierungskonzept, Artefakte zur Unterstützung der Erarbeitung sowie eine Werkzeugunterstützung erreicht. Das **übergeordnete Ziel** der Spezifikationstechnik ist die Unterstützung der Planung, Konzeption und Integration von Prescriptive Analytics Lösungen für die Produktion.

**Zielgruppe** der Spezifikationstechnik sind produzierende Unternehmen, welche eine initiale Menge an Analytics Use Cases in der Produktion umgesetzt haben. Weiterhin hilfreich ist es, wenn Kompetenzen im Management der IT-Unternehmensarchitektur durch Methoden des Enterprise Architecture Managements vorliegen. Sollte dies nicht der Fall sein, erhöhen sich die Aufwände in den entsprechenden Phasen. Diese Vorbedingungen entsprechen aufgrund der vorausgesetzten Menge an Ressourcen und Organisationsstrukturen eher dem Typus eines Großunternehmens<sup>1</sup>. Weiterhin wird vorausgesetzt, dass das vorliegende Produktionssystem bereits existiert. Eine Anwendung bei einer Produktionsneugestaltung oder Produktionssystementwicklung steht nicht im Fokus. Die Rolle des Analytics Architekten<sup>2</sup> stellt den Kernadressaten der Ausarbeitung dar.

## 1.3 Vorgehensweise und Forschungsmethode

Zur Sicherstellung einer strukturierten Vorgehensweise wird die **Design Science Research Methodology** (DSRM) nach PEFFERS ET AL. verwendet (vgl. [PTR+07]). **Design Science Research** befasst sich mit der Erweiterung der Fähigkeiten von Menschen und


---

<sup>1</sup> Die Reife der Disziplin des EAM wächst in der Regel mit der Unternehmensgröße [Han13, S. 144].

<sup>2</sup> Aus Gründen der besseren Lesbarkeit wird im Folgenden auf die gleichzeitige Verwendung weiblicher und männlicher Sprachformen verzichtet und das generische Maskulinum verwendet. Sämtliche Personenbezeichnungen gelten gleichermaßen für beide Geschlechter.

Organisationen durch das Design neuer und innovativer Artefakte [HTP+04]. Ein praxisnaher Charakter steht im Vordergrund. Der Forschungsansatz der Design Science stammt aus den Ingenieurwissenschaften und wurde als Methode in der Wirtschaftsinformatik aufgegriffen [Sim96]. Ein stark iteratives Vorgehen zur Erzeugung einer zufriedenstellenden Lösung bildet den Kern [Hev07, S. 3]. Dieses basiert auf der Synthese von Feedback aus der Praxis und der vorliegenden Wissensbasis [Hev07, S. 3]. Das Ziel der Anwendung der Design Science Research Methodology ist die Erzeugung hilfreicher Artefakte zur Lösung von geschäftsrelevanten Problemstellungen [MS95].

Es wird sich an der Definition eines Artefakts nach MARCH UND SMITH orientiert [MS95]. Ein (IT-)Artefakt stellt ein Konstrukt, ein Modell, eine Methode oder eine Instanziierung einer Methode dar. Sie helfen direkt bei der Umsetzung einer Problemstellung in eine Lösung [HTP+04]. In Bild 1-1 ist der Zusammenhang zwischen den Aktivitäten nach PEFFERS ET AL. sowie den Kapiteln der Ausarbeitung zusammengefasst.

<b>Kapitel 1</b> <b>Motivation</b>	<b>1) Problemidentifikation und Motivation</b> <ul style="list-style-type: none"> <li>Übersicht über Grundaufbau der Ausarbeitung und Kontextuierung sowie Motivation des Entwicklungsziels</li> </ul>
<b>Kapitel 2</b> <b>Problemanalyse</b>	<b>2) Entwurfsziel definieren</b> <ul style="list-style-type: none"> <li>Definition der <b>konstituierenden Begriffe</b> der Ausarbeitung</li> <li>Herausarbeiten der <b>Problematik</b> der Spezifikation von Prescriptive Analytics Use Cases im Produktionsumfeld</li> <li><b>Ableiten von 3 Handlungsfeldern</b></li> </ul>
<b>Kapitel 3</b> <b>Stand der Technik</b>	<ul style="list-style-type: none"> <li>Aufstellen von <b>8 Zielanforderungen</b> aus der Synthese der Problematik</li> <li><b>Vergleichs des Stands der Technik</b> mit den Anforderungen</li> <li><b>Ableiten eines Handlungsbedarfs</b> durch fehlende Anforderungserfüllung</li> </ul> 
<b>Kapitel 4</b> <b>Spezifikationstechnik</b>	<b>3) Entwurf und Entwicklung</b> <ul style="list-style-type: none"> <li><b>Erforschung der Spezifikationstechnik.</b> Diese besteht aus einem Vorgehensmodell, Modellierungskonzept, Hilfsmitteln, einer Werkzeugunterstützung sowie einem Fundament (Grundlagenwissen)</li> <li><b>Integration von Teilveröffentlichungen</b> in die sachlogische Abfolge</li> </ul>
<b>Kapitel 5</b> <b>Demonstration und Evaluation</b>	<b>4) Demonstration</b> <ul style="list-style-type: none"> <li><b>Demonstration der Anwendbarkeit und Vorgehen</b> bei der Anwendung der Systematik in einem realen Anwendungsszenario</li> </ul> <b>5) Evaluation</b> <ul style="list-style-type: none"> <li>Bewertung der Systematik hinsichtlich der aufgestellten Anforderungen</li> <li>Diskussion der Ergebnisse vor dem Hintergrund der Integration in die existierende Wissensbasis</li> </ul>
<b>Finale</b> <b>Spezifikationstechnik</b>	<b>6) Kommunikation</b> <ul style="list-style-type: none"> <li>Teilveröffentlichungen auf Konferenzen (9) durch Manuskript und Vortrag und in Journals durch Artikel (3)</li> <li>Dissemination der Forschungsergebnisse durch die Veröffentlichung der Ausarbeitung</li> </ul>

Prozessiterationen

Bild 1-1: Zusammenhang zwischen der Kapitelstruktur der Ausarbeitung und Aktivitäten in Anlehnung an PEFFERS ET AL. [PTR+07]

Für jedes zu entwickelnde Artefakt muss eine passende Forschungsmethode ausgewählt werden. Die Kombination mehrerer Artefakte ergibt ein Ensemble Artefakt [SHP+11]. Die Spezifikationstechnik ist als Ensemble Artefakt anzusehen. Ziel des Ansatzes der Ausarbeitung ist die Entwicklung einer Spezifikationstechnik. Der Fokus liegt auf der Strukturierung nach aufgabenspezifischen Gesichtspunkten. Eine kreative Leistung des Anwenders wird trotzdem benötigt [Dum10, S. 6]. Die Ziele der Lösungsentwicklung werden im Rahmen der Ausarbeitung implizit durch Anforderungen abgebildet. Sie werden zur Bewertung des Stands der Technik anhand der vorhergehenden Problemanalyse genutzt. Darauf basierend wird eine Lösung entwickelt, demonstriert und evaluiert. Die Kommunikation der Ergebnisse erfolgt durch die Dissemination der Ausarbeitung als solche.

Angelehnt an die Struktur der Forschungsmethode werden die folgenden Kapitel aufgebaut. Es wird auf die verwendeten Methoden zur Erarbeitung der Ergebnisse in den Kapiteln genauer eingegangen. Eine Kurzzusammenfassung der verwendeten Methoden zur Erarbeitung von Teilergebnissen ist Tabelle 1-1 zu entnehmen. In der Ausarbeitung werden die einzelnen Teilergebnisse nicht evaluiert. Diese wurden in den entsprechenden Teilveröffentlichungen bereits evaluiert.

*Tabelle 1-1: Überblick über die verwendete Methode je Kapitel und Artefakt inklusive eines Verweises auf die dazugehörige Veröffentlichung*

<b>Artefakt</b>	<b>Forschungsmethode</b>	<b>Erforscht und Veröffentlicht in</b>	<b>Kapitel</b>
Taxonomie für Prescriptive Analytics Use Cases	Taxonomie-Entwicklung nach [NVM13]	<i>CIRP CMS 2025</i> [WNG+25]	4.2.2
Design Prinzipien für Prescriptive Analytics Use Cases	Design Prinzipien Entwicklung nach [MGO20]	<i>CIRP DESIGN 2024</i> [WME+24]	4.2.3
Capability Map für Prescriptive Analytics in der Produktion	Generische Capability Map Entwicklung nach [vP23]	<i>CIRP CMS 2025</i> [WLB+25]	4.5.2
Use Case Canvas für Prescriptive Analytics Daten	Design Science Research Methodology nach [PTR+07]	<i>CPSL 2024</i> [WMK+24]	4.5.4
Referenzarchitektur zur Integration von Prescriptive Analytics Use Cases	Referenzarchitektur Entwicklung nach [GA11]	<i>Mathematics (MDPI)</i> [WMN+24]	4.5.5
Referenzpipeline für Prescriptive Analytics Use Cases		<i>IEEE ADACIS 2023,</i> <i>Mathematics (MDPI)</i> [WMN+24, WMW+23]	4.5.6

## 1.4 Struktur der Ausarbeitung

Zur Strukturierung wird die Problemstellung in **Kapitel 2** in Teilprobleme zerlegt (Problemanalyse). Dazu werden in einem ersten Schritt die für die Ausarbeitung konstituierenden Begriffe definiert. Darauf aufbauend wird die Problemstellung im Kontext des Betrachtungsobjekts „Prescriptive Analytics Use Case für die Produktion“ analysiert. Ausgehend vom Gestaltungsobjekt wird der Gestaltungsprozess der ganzheitlichen Konzeption von Prescriptive Analytics Use Cases untersucht. Eine Abgrenzung zu Ansätzen, welche sich nur auf die Entwicklung eines einzelnen Use Cases beschränken, wird vorgenommen. Zur Verfeinerung der Problematik werden strukturierende Handlungsfelder gebildet. Die Teilprobleme werden in acht Anforderungen, welche aus drei Handlungsfeldern stammen, überführt. Diese dienen als Maßstab für die spätere Bewertung des Stands der Technik.

Mithilfe der Anforderungen wird der Stand der Technik in **Kapitel 3** auf eine mögliche Lösung des Designproblems mit existierenden Ansätzen oder deren trivialer Kombination überprüft. Dafür werden existierende Vorgehensmodelle, allgemeine Artefakte und Gestaltungswissen für Prescriptive Analytics basierend auf den Handlungsfeldern untersucht. Insbesondere Artefakte zur ganzheitlichen Konzeption von Prescriptive Analytics Use Cases werden untersucht.

Basierend auf der Diskrepanz zwischen den erhobenen Anforderungen und dem Stand der Technik wird in **Kapitel 4** eine Spezifikationstechnik erarbeitet. Diese besteht aus fünf Kernelementen. Neben einem Vorgehensmodell, einem Modellierungskonzept, Artefakten zur Unterstützung und einer Werkzeugunterstützung wird ein Strukturierungsrahmen bereitgestellt. Dabei werden bewährte Methoden aus dem Stand der Technik sowie eigene Vorveröffentlichungen sinnvoll integriert. Insbesondere auf die Herleitung und Interdependenzen der einzelnen Schritte wird gesondert eingegangen.

Im Einklang mit der Forschungsmethode wird in **Kapitel 5** die Funktionsweise der Spezifikationstechnik an einem Anwendungsbeispiel in der IoT Factory Gütersloh demonstriert. Mithilfe der Spezifikationstechnik werden alle relevanten Schritte durchlaufen und die sachlogische Abfolge und Funktionalität beispielhaft aufgezeigt. Teil der Evaluation ist der Abgleich der Ergebnisse mit den in der Problemanalyse abgeleiteten Anforderungen. Die Gebrauchstauglichkeit der Spezifikationstechnik wird über Evaluationsinterviews bewertet und kritisch reflektiert. Basierend auf den Ergebnissen wird die Spezifikationstechnik unter Berücksichtigung des Praxisfeedbacks aus Kapitel 5 und des Stands der Technik diskutiert.

**Kapitel 6** schließt die Ausarbeitung ab. Grenzen der vorliegenden Untersuchung werden diskutiert. Aufbauend auf einer kurzen inhaltlichen Zusammenfassung werden Anknüpfungspunkte und weitere Forschungsfragen des behandelten Themenfeldes aufgezeigt. So werden weitere Handlungsoptionen in Richtung Grundlagenforschung und Erhöhung der technischen Reife der zugrundeliegenden Mechanismen und Bestandteile eruiert.

## 2 Problemanalyse

Die **Problemanalyse** zeigt die Herausforderungen und möglichen Nutzenpotenziale innerhalb der zugrundeliegenden Handlungsfelder auf. Diese werden ausgehend von der in Kapitel 1 erläuterten Problematik beschrieben. Je Handlungsfeld werden Anforderungen an die Spezifikationstechnik abgeleitet.

**Kapitel 2.1** stellt die benötigten Begriffsdefinitionen und die Einordnung der Arbeit bereit. In **Kapitel 2.2** wird die allgemeine Entwicklung der Produktion hin zur Vision der Industrie 4.0 beschrieben. Auf Herausforderungen in der aktuellen Umsetzung des Konzepts der Industrie 4.0 wird gesondert eingegangen. **Kapitel 2.3** widmet sich der Aufarbeitung der Potenziale des Einsatzes von Data Analytics in Form von Use Cases im industriellen Kontext. **Kapitel 2.4** verfeinert dieses Verständnis über die Potenziale von Prescriptive Analytics im Speziellen. In **Kapitel 2.5** werden verschiedene etablierte Ansätze zur Entwicklung von Analytics Use Cases diskutiert.

### 2.1 Begriffsdefinitionen und Einordnung der Ausarbeitung

Im Folgenden werden die für die Ausarbeitung konstituierenden **Begriffsdefinitionen und eine Einordnung** bereitgestellt. Dies schafft ein einheitliches Verständnis für die zentralen Begrifflichkeiten. Weiterhin wird eine implizite Abgrenzung von anderen Begriffsverständnissen durch eine eindeutige Festlegung sichergestellt.

Zuerst wird der Begriff der Spezifikationstechnik in **Kapitel 2.1.1** definiert. Darauf aufbauend werden die Begriffe Produktion und Industrie 4.0 in **Kapitel 2.1.2** verortet und definiert. **Kapitel 2.1.3** definiert Prescriptive Analytics basierend auf dem Verständnis der Industrial Data Science. Abschließend wird der Begriff der Analytics Lösung vom Analytics Use Case in **Kapitel 2.1.4** abgegrenzt. Das Ziel ist die Erläuterung der Grundbegriffe für die Spezifikation von Prescriptive Analytics Lösungen in der Produktion.

#### 2.1.1 Spezifikationstechnik

**Spezifikationstechniken** erfüllen die Funktion eines „Logbuchs“ der Entwicklung [Fra06, S. 8]. Sie fokussieren in der Regel semi-formale Spezifikationen. Das heißt, die dargestellten Sachverhalte sind präziser als lose Formulierungen (umgangssprachliche Spezifikationen) und weniger formell als z. B. mathematisch definierte Zusammenhänge (formale Spezifikationen) dargestellt [CJS98, GEK01]. Sie finden unter anderem in der Konzeption von intelligenten technischen Systemen aus dem Bereich der Mechatronik Anwendung (z. B. [Fra06, Sch18, Hei24]). Die Konzeption beschreibt nach EHRENSPIEL den Vorgang, bei dem ein Überblick über die prinzipielle Funktionsweise eines Systems erlangt wird [Ehr09, S. 251].

Aufbauend auf der Synthese der Analyse des Begriffes der Spezifikationstechnik von FRANK [Fra06], SCHNEIDER [Sch18, S. 11] und HEIHOFF-SCHWEDE [Hei24, S. 20] wird im Folgenden mit einer Spezifikationstechnik die **Abstimmung der Beziehungen zwischen Sprache, Methode und Werkzeug** mit dem Zweck der Architekturmodellierung beschrieben. Es wird keine explizite Fokussierung auf ein Werkzeug vorausgesetzt [Hei24, S. 20]. Spezifikationstechniken können zur Analyse, Gestaltung und Bewertung von Architekturen genutzt werden [Hei24, S. 7]. Sie befähigen verschiedene Akteure domänenübergreifend effizient zu kommunizieren [GN12, S. 8]. Im angloamerikanischen Sprachraum wird in ähnlicher Weise zur Spezifikationstechnik ein *Architecture Description Framework* definiert [IEC42010, S. 16]. Im Folgenden werden die Bestandteile einer Spezifikationstechnik definiert.

Eine **Architektur**, abgebildet in Form eines Modells, soll verschiedene Stakeholder befähigen, sich über komplexe domänenübergreifende Sachverhalte auszutauschen [Lan17, S. 61]. Sie beschreibt fundamentale Konzepte und Eigenschaften eines Systems [ISO42020, S. 2]. Dabei sind **Systeme** mitsamt ihrer Elemente und Beziehungen in eine Umgebung eingebettet [Lan17, S. 3, ISO42020, S. 2]. **Unternehmensarchitekturen** dienen, aufbauend auf der Definition der Architektur, zur Gestaltung und Umsetzung von Organisationsstrukturen, Geschäftsprozessen, Informationssystemen und Infrastrukturen eines Unternehmens [Lan17, S. 3]. Architekturen werden oftmals aus dem bestimmten Blickwinkel einer **Domäne** betrachtet [Lan17, S. 48]. Eine Architektur kann durch Instanziierung aus einer **Referenzarchitektur** abgeleitet werden [ISO20547-3, S. 2]. Dies dient primär der Weiterverwendung in einem spezifischen Kontext [ISO20547-3, S. 2]. Weitere Verwendungszwecke umfassen den Vergleich und Abgleich existierender Architekturen [ISO20547-3, S. 2].

Aufgrund der hohen Interdependenz der Begriffe Architekturmodell, Sprache, Methode und Werkzeug benötigt es Ansätze zur Abstimmung dieser Begriffe aufeinander. Verschiedene Domänen generieren ihre eigenen **Modelle**, sprechen ihre eigenen **Sprachen**, verwenden eigene **Methoden** und nutzen ihre eigenen **Werkzeuge**. Dadurch ist eine holistische Betrachtung, Kommunikation und Entscheidungsfindung über die Domänen hinweg beeinträchtigt [Lan17, S. 3].

Ein (Architektur-) **Modell** beschreibt die zweckgebundene eindeutige Abstraktion in Form eines Konzepts der vorliegenden Domäne [Lan17, S. 48, FMS12]. Modelle werden modelliert. Modellierung beschreibt den Prozess der bewussten Erstellung eines Modells aus einem vorliegenden Problem- und Lösungsraum mit einem definierten Zweck [Lan17, S. 48, FMS12, S. 21]. **Partialmodelle** hingegen beschreiben lediglich einen Ausschnitt des Gesamtmodells, welcher basierend auf spezifischen Anforderungen angepasst ist [Pat82, S. 46]. Um eine Verwechslung mit dem Verständnis des Modells aus der Data Science (vgl. [VDI/VDE 3714 Blatt 1]) zu verhindern, wird im Folgenden der Begriff des Architekturmodells verwendet.

Eine **Sprache** zur Modellierung definiert Regeln und Konventionen, welche möglichen Verbindungen zwischen Elementen in Modellen vorliegen dürfen [FMS12, S. 19]. Das Konzept dahinter wird in einem sogenannten Metamodell abstrahiert zusammengefasst [FMS12, S. 371]. Zur Anleitung der Architekturmodellierung gibt es **Methoden** [Lan17, S. 140]. Eine Methode zur Architekturmodellierung fasst Aktivitäten, Techniken und Konventionen zur Implementierung von Prozessen (oder eines Prozesses) zusammen. Sie wird im Allgemeinen durch Werkzeuge unterstützt [FMS12, S. 21]. **Werkzeuge** zur Architekturmodellierung werden zur IT-gestützten Definition, Erstellung, Bearbeitung und Visualisierung von Architekturen eingesetzt [Lan17, S. 9].

**Bedeutung im Kontext der Ausarbeitung:** Der Begriff der **Spezifikationstechnik** dient als zusammenfassendes Element für einen Beitrag zur Strukturierung einzelner Ansätze zum Zwecke der Konzeption. Der Ansatz des „Logbuchs der Entwicklung“ dient der domänenübergreifenden Spezifikation der Prescriptive Analytics Use Cases. Im Kontext dieser Ausarbeitung wird das Artefakt der Spezifikationstechnik für den Anwendungsbereich der Planung, Konzeption und Integration von Prescriptive Analytics Lösungen für die Produktion entwickelt.

### 2.1.2 Produktion und Industrie 4.0

Zur Einordnung der Verwendung von Prescriptive Analytics in der **Produktion** ist die Definition einer Reihe von Basisbegriffen erforderlich. Im Folgenden wird die sachlogische Verschachtelung von Produktion, Produktionssystemen und Fabriken erläutert. Aufbauend darauf wird das Konzept der Industrie 4.0 definiert. Die Implikationen im Kontext der Ausarbeitung werden beleuchtet.

#### Produktion und Produktionssysteme

SCHUH UND SCHMIDT aggregieren die Definition des Begriffs **Produktion** verschiedener Autoren wie folgt:

*„Im Sinne eines betrieblichen Wertschöpfungsprozesses bezeichnet der Begriff Produktion die Transformation von Materialien, Diensten, Rechten und Informationen.“ [SS14, S. 2]*

Der Begriff **Transformation** im Kontext der Produktion hebt die Wandlung von Input- in Output-Faktoren hervor. Eine Kombination der Elementarfaktoren Arbeit, Material und Maschinen mit dem übergeordneten Zweck der Leistungserstellung fasst den Begriff Produktion in hinreichender Form zusammen [SS14, S. 2]. Produktionssysteme stellen die einfachste Organisationsform von Transformationsprozessen dar. Die Prozesse können gleichartig oder verschieden sein. Eine Beschränkung auf einen Standort wird im Begriff des Produktionssystems nicht vorgenommen [SS14, S. 3]. Ein Überblick zu den Zusammenhängen der Begriffe ist in Bild 2-1 dargestellt.

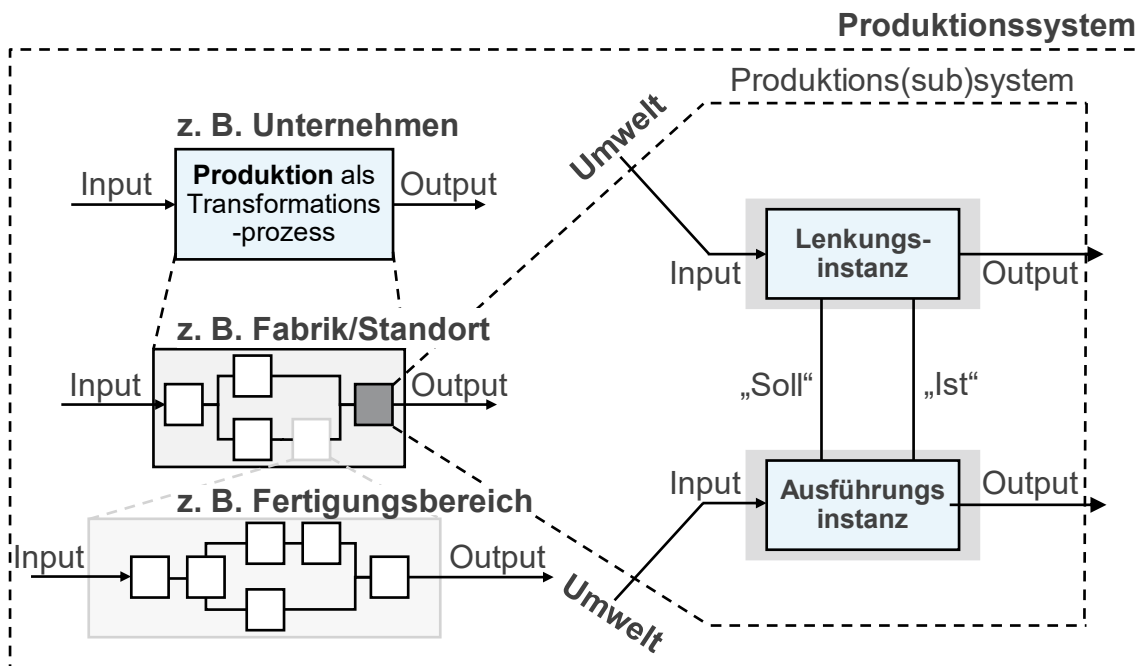


Bild 2-1: Elemente eines Produktionssystems nach SCHUH UND SCHMIDT [SS14, S. 3]

Ein **Produktionssystem** wird im Kontext des **Unternehmens** eingegliedert. Eine **Fabrik** oder ein **Standort** kann verschiedene **Fertigungsbereiche** mit jeweils variierenden **Produktionssystemen** beinhalten. In einem Produktionssystem wird eine **Lenkungsinstanz** und eine **Ausführungsinstanz**<sup>3</sup> zur Transformation genutzt. Das heißt, das Umwelteinflüsse berücksichtigt werden und ein Soll-Ist Abgleich erfolgt [SS14, S. 3]. Dabei beschreibt die **Fertigung** (Teilefertigung und Montage) die Transformation von definierten Werkstücken in funktionsfähige Erzeugnisse [GP14, S. 16]. Teil des Begriffes Produktion sind auch die Energie- und Verfahrenstechnik [GP14, S. 16].

## Industrie 4.0

Die **Industrie 4.0** ist eine Eigenbegriffsschaffung, erwachsen aus einer politischen Initiative. Dabei dient dieser primär politisch geprägte Begriff als Sammelbecken für eine Reihe von Konzepten mit einem Fokus auf der Integration neuartiger Methoden in Wertschöpfungsketten produzierender Unternehmen. Über alle Autoren hinweg stehen die ganzheitliche digitale Transformation und der Einsatz neuer digitaler Technologien in der Produktion im Vordergrund. [HKS+22, S. 5, Sie16, S. 22, WMH+18, S. 1]

Das Konzept der **Smart Factory** stammt unmittelbar aus der Initiative Industrie 4.0. Sie stellt die Instanziierung und Fokussierung des Konzepts für den Produktions- und Fabrikkontext dar [BHF+23, S. 14]. Sogenannte **cyber-physische-Systeme** (CPS) bilden den Grundstein für die Elemente der Smart Factory [ZWD+21, S. 795]. CPS sind mechatronische Systeme mit der Fähigkeit, sich über Produkte, Geräte und Objekte hinweg zu

<sup>3</sup> Diese Instanzen bilden die Grundlage für die Einführung von Prescriptive Analytics. Je nach Reifegrad wird die Lenkungsinstanz ersetzt, unterstützt oder beeinflusst.

vernetzen und über Anwendungsgrenzen hinaus zu interagieren. Analog dazu existiert das Konzept des cyber-physischen Produktionssystems (CPPS) [Rot16, S. 29]. CPPS und CPS leisten einen elementaren Beitrag zur ressourceneffizienten, kundenindividuellen und humanzentrierten Produktion [GP14, S. 5]. Oftmals wird für das Konzept der CPPS auch der Begriff des Internets der Dinge (IoT) verwendet. Dieser steht für die Vision, dass Gegenstände der Umgebung direkt an das Internet angebunden werden und so einen verteilten, bidirektionalen Informationsaustausch über viele kleine Zugangspunkte ermöglichen [MF10, S. 1]. Nach GAUSEMEIER UND PLASS führt der Einsatz von CPS zu einer Smart Factory [GP14, S. 5].

**Bedeutung im Kontext der Ausarbeitung:** Das Konzept der Industrie 4.0 mit der Ausprägung der Smart Factory bildet die Grundlage für die Analyse des Einsatzes von Prescriptive Analytics Lösungen in der Produktion. Es repräsentiert das relevante zu betrachtende System (das sogenannte System under Observation), welches durch den Einsatz von Prescriptive Analytics Use Cases transformiert und optimiert werden soll. Im Fokus steht die betriebliche Effizienz in der Produktion zu steigern.

### 2.1.3 Prescriptive Analytics

**Prescriptive Analytics** ist eine Teilmenge des Bereichs der Data Science [Cao18, S. 4]. **Data Science** beschreibt die Wissenschaft der Daten [Cao18, S. 4]. Industrial Data Science<sup>4</sup> stellt eine Instanziierung der allgemeinen Definition von Data Science mit der fest definierten Domäne „Industrie“ dar [Rei16].

Industrial Data Science umfasst den Einsatz von Datenanalyse, maschinellem Lernen und ähnlichen Analysewerkzeugen in der Industrie [DWS22, WGB+21, NSM+20, MWS+19]. Weiterhin wird die Querschnittsrolle über Statistik, Informatik und die Ingenieurwissenschaften hinweg betont [Rei16, BSJ+18, SSS+20, KJR+18, S. 164, RKD17]. Im Kontext der vorliegenden Ausarbeitung wird **Industrial Data Science (IDS)** aufbauend auf den vorher genannten Quellen definiert als:

*„[...] ein interdisziplinäres Gebiet, das die Erforschung, Gestaltung und Umsetzung von Data Science Methoden in allen Facetten industrieller Prozesse umfasst. Der Anwendungskontext sind Industrieunternehmen, das heißt Organisationen, deren Wertschöpfung hauptsächlich auf Produktions- und Produktentwicklungsprozessen beruht. Das Ergebnis des Implementierungsprozesses eines IDS-Use Cases ist eine funktionierende IDS-Lösung, die mit Hilfe von Werkzeugen und Methoden erfolgreich in ein reales Unternehmen eingebettet wird.“*  
[EWB+24, S. 2]

---

<sup>4</sup> In anderen Quellen wird auch der Begriff der Industrial AI oder Manufacturing AI synonym verwendet (vgl. z. B. [HHS24, S. 27, McC24]). Im Rahmen der Ausarbeitung werden die Begriffe Data Science und Analytics genutzt um den ganzheitlichen Ansatz und die Inkludierung von nicht KI-Ansätzen (z. B. Dashboard-basierte Use Cases) zu verdeutlichen.

Diese Definition beinhaltet Aspekte rund um Menschen, Prozesse, Infrastruktur und Unternehmenskultur [MMB+22, EWB+24, Uli13]. Es stehen die im Anwendungsfeld spezifischen Herausforderungen, Best Practices und inhärenten Implikationen der betrachteten Domäne im Vordergrund [EWB+24]. Über alle betrachteten Autoren hinweg wird die Interdisziplinarität von Industrial Data Science hervorgehoben [RKD17, EWB+24, BSJ+18]. Darüber hinaus betonen verschiedene Autoren den Bedarf für einen ganzheitlichen Ansatz inklusive Managementaspekten beim Umgang mit IDS Projekten [DWS22, EWB+24]. *DEUSE ET AL.* argumentieren, dass sich Industrial Data Science als weitere Methode in den Werkzeugkasten eines produktionsorientierten Ingenieurs einordnen wird [DWS22, S. 2].

Die **Hauptaufgaben** der Industrial Data Science sind das Verfügbarmachen von Daten, die Analyse der gesammelten Daten sowie deren Integration zur kontinuierlichen Verwendung. Dem zugeordnet ist die Administration der zugrundeliegenden Datenbanken und Datenelemente [DWS22, S. 3]. IDS als Werkzeug dient der Verbesserung üblicher Prozesse im Produktionskontext wie der Produktionsplanung und -steuerung [NHQ+17, S. 47, WRE+23]. Die Industrial Data Science bedient sich an Methoden aus den Bereichen Visualisierung, Data Analytics und Künstlicher Intelligenz [NSM+20, S. 734]. Auf die Rolle von Künstlicher Intelligenz in der Industrial Data Science wird in Anhang A1.1 vertiefend eingegangen.

Dazu komplementär beschreibt die Datenanalyse (**Data Analytics**) eine lose umrissene Sammlung an Theorien, Technologien, Werkzeugen und Prozessen, welche den Anwender befähigen, die vorliegenden Daten tiefgreifend zu durchdringen und handlungsorientierte Erkenntnisse aus den Daten abzuleiten [Cao18, S. 4]. Für die Strukturierung von Data Analytics gibt es verschiedene Ansätze. Der etablierte Strukturierungsansatz nach GARTNER wird im Folgenden genauer erläutert. Es wird unterschieden zwischen den Stufen Descriptive, Diagnostic, Predictive und Prescriptive Analytics (vgl. Bild 2-2).

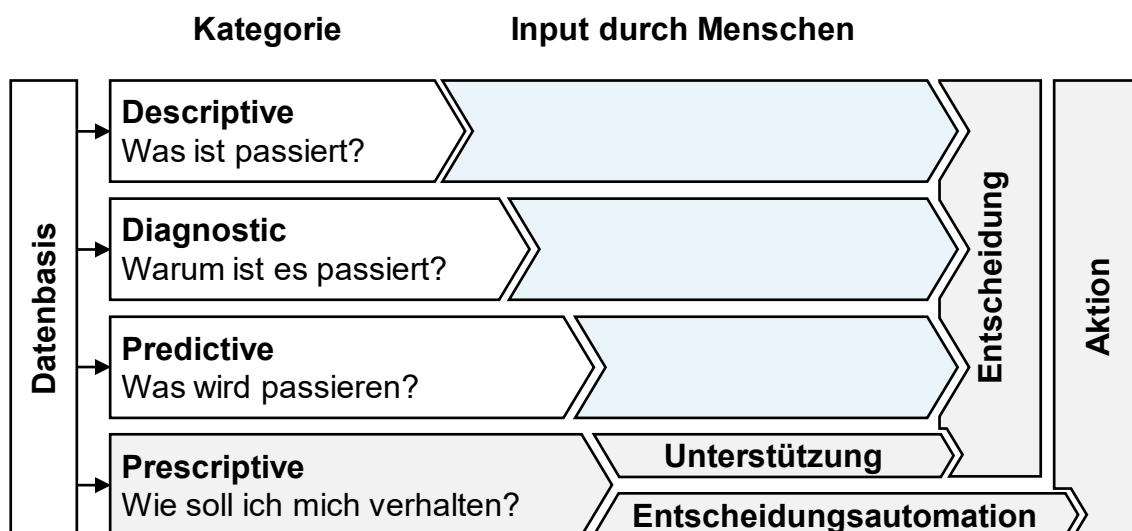


Bild 2-2: Data Analytics Stufen nach GARTNER [SSK+14-ol, S. 1]

Alle Data Analytics Stufen transformieren Daten aus einer Datenbasis in Entscheidungen und dann in Aktionen (Definition siehe Anhang A1.2). Der Grad der Einbindung des Menschen nimmt mit zunehmender Stufe ab. Die Analytics Stufen **Descriptive**, **Diagnostic** und **Predictive Analytics** fokussieren sich auf das Generieren von Erkenntnissen basierend auf Daten. Dies meint die Beschreibung (z. B.: Condition Monitoring [FKF+16]), Diagnose oder Vorhersage (z. B.: Standardzeit-Vorhersage [WRE+23]) [SSK+14-ol, Cao18]. Die Descriptive Analytics fokussiert die Beschreibung von Zuständen in Form von aufbereiteten Daten (z. B. durch Statistik) [Cao18, S. 4]. Die Diagnostic Analytics legt einen Schwerpunkt auf die Ermittlung von Ursachen (z. B. in Fehlerfällen) [SSK+14-ol]. Predictive Analytics konzentriert sich auf die Vorhersage von unbekanntem zukünftigen Ereignissen oder Zuständen [Cao18, S. 4].

**Prescriptive Analytics** beantwortet die Frage „*Wie soll ich mich verhalten?*“ [SSK+14-ol, Cao18, S. 4]. Der Fokus liegt auf der Unterstützung oder Automatisierung von Entscheidungsabläufen [Cao18, S. 4]. Die Definition nach CAO und die Analytics Stufen nach GARTNER stellen den Quasistandard dar, sind aber nur bedingt zur Abgrenzung geeignet. Viele Autoren leisten ihre eigene Definition von Prescriptive Analytics (vgl. [PP20, S. 76, SCP+21, LSR+19, S. 1938, DD21, S. 6, AAB+20, S. 16206, GGT23, S. 386, LP23, FNP+19, S. 579, Cao18, S. 4, LBA+20, S. 58, PLN+21, S. 1819, SST+23, S. 338, BPM+20, S. 92383]). Diese weichen in der Formulierung ab, treffen aber den gleichen Wesenskern. Das Ziel von Prescriptive Analytics ist die Erzeugung einer ausführbaren Entscheidung: Dabei zeichnet sich eine ausführbare Entscheidung (Englisch: *Actionable Decision*) durch einen empfehlenden Charakter aus.

Ergänzend gibt es diverse Subdefinitionen von Autoren für **untergeordnete Begriffsfelder** wie Prescriptive Maintenance [PLN+21, S. 1820, WH22, S. 1]. Dies ist unter anderem darin begründet, dass Prescriptive Analytics ein aufstrebendes, bisher aber nicht stark etabliertes Feld darstellt [FNP+19, S. 576]. Im Vergleich zu den anderen Analytics Stufen (insbesondere Deskriptive und Predictive) ist die Forschung zu Algorithmen und möglichen Ansätzen für Prescriptive Analytics noch weniger ausgereift [LBA+20, S. 57]. Das Themenfeld ist bestimmt von Ambiguitäten und Schnittmengen zwischen diversen Themenfeldern [SZ18, S. 6]. Es liegt eine enge Verschachtelung von Prescriptive Analytics mit den Ergebnissen von Predictive Analytics vor [ADF+17]. Vorverarbeitete Daten aus anderen Analytics Stufen (vgl. Bild 2-2) sind wichtige Eingangsgrößen, da diese initial für die menschenzentrierte Entscheidungsfindung generiert wurden [HP16, S. 1]. Diese Verschachtelung gilt als bisher wenig erforscht [HP16].

**Bedeutung im Kontext der Ausarbeitung:** Die Industrial Data Science nutzt verschiedenste Methoden zur Analyse und Optimierung mithilfe von Daten – darunter auch KI. Im Vordergrund stehen eine technologieoffene Optimierung und Verbesserung der Produktion ohne expliziten Fokus auf der reinen Nutzung spezifischer KI-Technologien. Im Fokus der Ausarbeitung liegen Prescriptive Analytics Use Cases. Diese sind als Teil der Industrial Data Science einzuordnen. Im Zentrum stehen Use Cases in produzierenden

Unternehmen mit dem Ziel der Entscheidungsunterstützung oder Entscheidungsautomatization. Im Begriffsverständnis sind Use Cases inkludiert, welche Actionable Decisions ermöglichen. Die für die Ausarbeitung relevanten Perspektiven sind primär die der Entscheidungstheorie (siehe Kapitel Anhang A1.2), der Data Analytics und der Geschäfts-sicht (hier: Produktion, siehe Kapitel 2.1.2) auf das Technologiefeld Prescriptive Analytics. Ein Abgleich mit angrenzenden Begriffsfeldern ist dem Anhang A1.3 zu entnehmen. Im Folgenden wird der Begriff Prescriptive Analytics und die damit verbundenen Aussagen nur im Kontext produzierender Unternehmen verwendet.

### 2.1.4 Analytics Use Cases und Lösungen

Nach COCKBURN beschreibt ein **Use Case** im klassischen Verständnis der Softwaretechnik eine mögliche Abfolge von Interaktionen zwischen einem Softwaresystem und seinem Umfeld. Dabei liegt immer ein vordefiniertes Ziel für die Interaktion vor. Das System ist für einen definierten Teil der Interaktion verantwortlich [Coc99, S. 15]. Das Anwendungsbeispiel (Englisch: Use Case) [BMW16, S. 4] beschreibt demnach eine konkrete **Lösung** zu einem Anwendungsszenario.

Je nach Fokus wird unter einem Use Case ein abweichender Handlungsrahmen verstanden. Es kann das ganze Geschäftsszenario inkludiert sein oder nur die Anwendung eines technischen Systems in einem Kontext. Die Umsetzung in einem konkreten **Projekt** wird teilweise auch als Use Case verstanden [DDV18, S. 85]. Projekte zur Implementierung von Analytics Use Cases kombinieren Datenquellen, um Erkenntnisse und umsetzbare Entscheidungen zu generieren [Cao18].

**Bedeutung im Kontext der Ausarbeitung:** Ein konkretes Umsetzungsprojekt realisiert basierend auf einem Konzept ein technisches System in einem Unternehmenskontext. Die daraus resultierende Lösung bildet eine konkrete Umsetzung eines Use Cases. Diese werden in Form von Projekten umgesetzt (Zuweisung von Anforderungen, Kapazitäten und zeitlicher Dringlichkeit). In der Ausarbeitung wird im Folgenden von Use Cases gesprochen. Bei erfolgreicher Umsetzung und Integration eines Systems in sein Umfeld, welches auf einem Use Case basiert, resultiert daraus eine Lösung.

## 2.2 Produktion auf dem Weg hin zur Vision der Industrie 4.0

Im Leitbild der **Vision der Industrie 4.0** stehen die Aspekte der Interoperabilität, Souveränität und Nachhaltigkeit [HKS+22, S. 5]. Zur Umsetzung dessen wird insbesondere das Prinzip der dezentralisierten Entscheidungsfindung in den Vordergrund gestellt [HPO16, S. 3932]. Diese Aspekte und Prinzipien werden durch die Umsetzung von Use Cases in der Produktion eingeführt oder bei Neuplanungen von Anfang an mitgedacht. Das folgende Kapitel gibt einen Überblick über die Vision der Industrie 4.0 sowie den aktuellen Stand der Umsetzung in der Praxis.

Auf Industrie 4.0 Use Cases wird in **Kapitel 2.2.1** eingegangen. **Kapitel 2.2.2** gibt einen Einblick in die Einstufung des Reifegrades eines produzierenden Unternehmens hin zur Vision der Industrie 4.0. Ergänzt wird dies in **Kapitel 2.2.3** durch eine allgemeine Beschreibung der Daten-Infrastruktur im Kontext der Industrie 4.0. **Kapitel 2.2.4** geht auf den Status Quo und Herausforderungen in der Umsetzung ein.

### 2.2.1 Industrie 4.0 Use Cases

Use Cases dienen der Manifestierung der allgemeinen Planungsziele der Transformation der Produktion hin zur Vision der Industrie 4.0 [BHF+23, S. 6]. Neue Technologien, die Verbesserung des Betriebs und die existierende heterogene IT-Systemlandschaft bilden das Spannungsfeld in der Transformation hin zum flächendeckenden Einsatz von **Industrie 4.0 Use Cases** [BHF+23, S. 6].

Es liegt ein großer Bedarf in der Industrie für die Unterstützung und Optimierung von Entscheidungen über alle Bereiche hinweg vor [GGT23, S. 387]. Ein wichtiger Aspekt zur Umsetzung ist die Integration von Daten für Entscheidungsprozesse [ZWD+21, S. 807]. Dabei steigt der Grad der Vernetzung in der Produktion und damit auch zwischen den zu treffenden Entscheidungen [ZWD+21, S. 794]. Daraus folgen vier Prinzipien für die Produktion auf dem Weg hin zur Vision der Industrie 4.0 nach SHI ET AL.:

- Erfassung von Sensordaten zur Analyse und Selbstorganisation. [SXX+20]
- Interkonnektivität, Interoperabilität und Echtzeitfähigkeit mit dem Ziel der immanenten Flexibilität des Systems. [SXX+20]
- Anwendung von KI-Technologien sowie Robotik und Algorithmen. [SXX+20]
- Anwendung von Virtual Reality und anderen immersiven Technologien. [SXX+20]

Diese Prinzipien haben Auswirkungen in verschiedenen Dimensionen der Smart Factory. Ein Überblick der Dimensionen einer Smart Factory ist Bild 2-3 zu entnehmen.

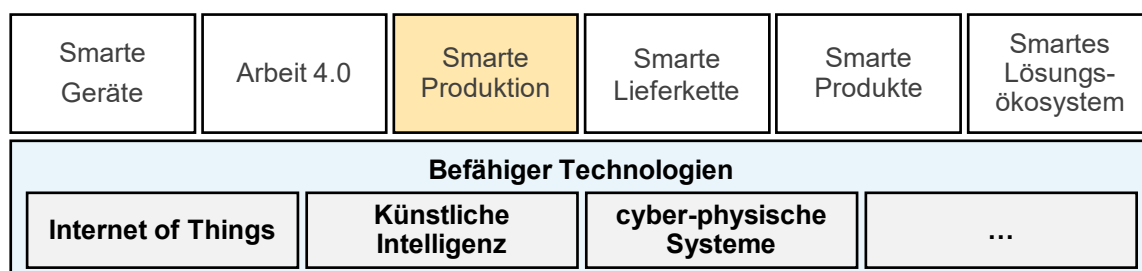


Bild 2-3: Dimensionen einer Smart Factory in Anlehnung an [BHF+23, S. 10, FDA19]

**Befähiger Technologien** sorgen verstärkt durch Innovationen für neue Geschäftsmodelle sowie effizienzgetriebene Verbesserungen. Dazu zählen das **Internet of Things**, **Künstliche Intelligenz** und **cyber-physische Systeme**. Basierend auf den Befähiger Technolo-

gien sind die Dimensionen der **smarten Geräte**, der **Arbeit 4.0**, der **smarten Produktion**, der **smarten Lieferkette**, der **smarten Produkte** und des **smarten Lösungsökosystems** von Bedeutung [BHF+23, S. 10].

Standard Industrie 4.0 Use Cases können zwischen Befähiger und zielorientierten Use Cases unterschieden werden [BHF+23, S. 237]. Befähiger Use Cases etablieren Grundlagentechnologien oder stellen Daten für andere Use Cases zur Verfügung. Zielorientierte Use Cases dienen einem definierten Zweck in der Produktion [BHF+23, S. 237]. Diese Use Cases umfassen Planungs- und Optimierungsaufgaben in der Produktionsplanung und -steuerung, Automatisierungslösungen sowie smarte Werker-Assistenzsysteme [BHF+23, S. 237, BHF+23, S. 14].

Auf dem Weg hin zum flächendeckenden Einsatz von Industrie 4.0 Use Cases gibt es andauernde Herausforderungen. Dazu zählen fehlende oder nicht etablierte Standards für Technologien [Del16]. Diese hemmen deren möglichen Einsatz im Produktionskontext [Del16]. Eine fehlende Transparenz zu möglichen Potenzialen der Industrie 4.0 mit undurchsichtigen Priorisierungsschemata in Bezug auf die Auswahl von möglichen Use Cases sorgt für offene Potenziale [Del16]. Dies liegt an der Menge an neuen möglichen Technologien zur Umsetzung [JKF+22]. Im besonderen Maße trifft der Sachverhalt auf Analytics Use Cases (als Teilmenge der Industrie 4.0 Use Cases) zu [EWB+24, Jop21, S. 119]. Dies liegt unter anderem an der fehlenden Einschätzbarkeit der Wirtschaftlichkeit der Umsetzung vor der initialen Sichtung der zur Verfügung stehenden Daten [EWB+24, Jop21, S. 119, RKK+20, S. 13].

**Bedeutung im Kontext der Ausarbeitung:** Nach GEISSBAUER ET AL. weicht in den letzten Jahren der starke Fokus auf Kostenoptimierung dem der Implementierung von Flexibilität und Transparenz in der Produktion [GBW22]. Prescriptive Analytics zählt auf genau diese Ansätze ein und kann als Befähiger in der Produktion hin zu einem flexiblen und transparenten Betrieb genutzt werden.

### 2.2.2 Industrie 4.0 Reifegradstufen

Zur Einstufung von Industrie 4.0 Vorhaben gibt es diverse **Industrie 4.0 Reifegrade** mit verschiedenen Schwerpunkten. Für eine detaillierte Übersicht wird auf [Pie24, S. 65] verwiesen. ACATECH stellt zur Bewertung des Reifegrades von Unternehmen einen Industrie 4.0 Reifegradindex bereit [SAD+20]. Das Reifegradmodell nach ACATECH wird aufgrund seiner breiten Akzeptanz vorgestellt. Die Reifegrade dienen dem Ableiten von konkreten Maßnahmen basierend auf der unternehmenseigenen Positionierung (vgl. Bild 2-4). Neben dem Modell nach ACATECH mit dem Fokus auf das gesamte Wirkgefüge gibt es verschiedene bereichs- oder domänenspezifische Ansätze [SSW23]. Beispiele sind Reifegradmodelle für die Verwendung einzelner Anwendungsfelder wie die Datenanalyse (z. B. für Data Analytics, vgl. [KAT+22]) oder Reifegradmodelle für das Design einzelner Elemente der Produktionsumgebung (z. B. für CPS; vgl. [Wes17]).

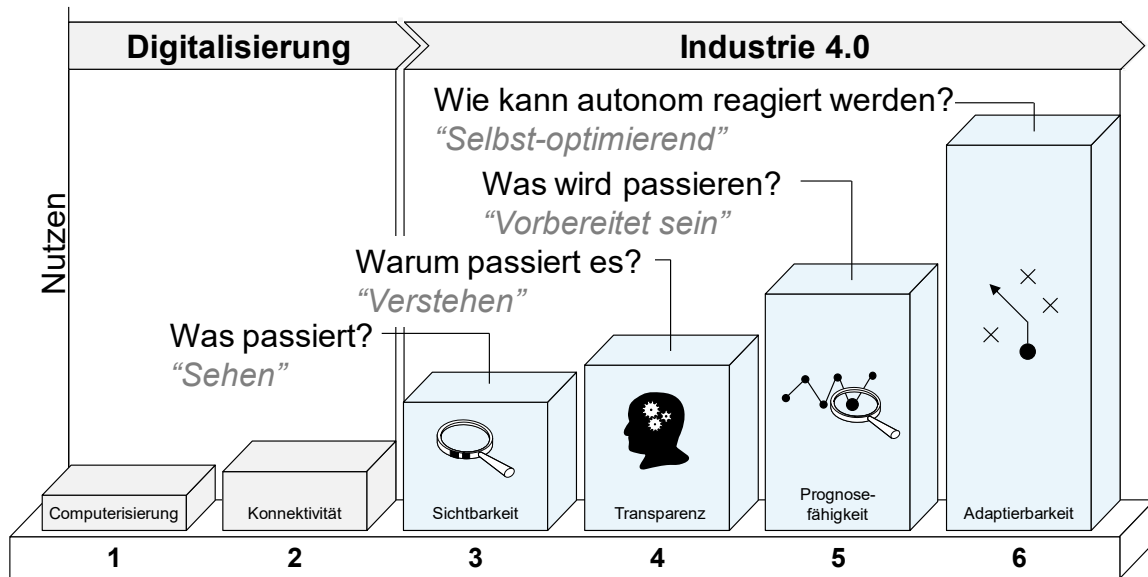


Bild 2-4: Reifegradstufen der Industrie 4.0 nach SCHUH ET AL. [SAD+20, S. 18]

Die **Digitalisierung** schafft die Grundlagen für die Reifegradstufen der **Industrie 4.0**. Dafür gibt es die ersten zwei Reifegradstufen der **Computerisierung** und **Konnektivität**. Diese sorgen erst dafür, dass Daten digital verfügbar sind. Darauf aufbauend werden **Sichtbarkeit**, **Transparenz** und **Analysefähigkeiten** für die **Industrie 4.0** erreicht. Die Reifegradstufen sind vergleichbar mit den Data Analytics Stufen Descriptive, Diagnostic und Predictive Analytics (siehe Kapitel 2.1.3). Im Unterschied dazu wird hier die ganze Produktion beschrieben. Die letzten beiden Stufen fokussieren sich auf die **Prognosefähigkeit** und die **Adaptierbarkeit** im Kontext der Produktion. Damit sind die Fähigkeiten der Vorhersage von Ereignissen und der selbstoptimierten Reaktion auf diese gemeint. [SAD+20, S. 18]

Durch die flächendeckende Fokussierung auf die Digitalisierung vieler produzierender Unternehmen sind viele auf den ersten vier Reifegradstufen basierende Use Cases bereits umgesetzt [GBW22]. Mit dem steigenden Digitalisierungsgrad geht eine erhöhte Wettbewerbsfähigkeit der Unternehmen einher [BVS+16]. Die Reifegradstufen Prognosefähigkeit und Adaptierbarkeit werden durch eine Summe an Technologien (Robotik, Optimierung, Analytics) bedient. Data Analytics spielt hier eine zentrale Rolle [SAD+20, S. 18]. Mit einer steigenden Reife steigt auch die Möglichkeit, Abläufe weitestgehend intelligent zu gestalten. Es entstehen autonome Systeme. Ein **System** gilt als autonom, wenn es ohne Eingriff von außen im vorgesehenen Geltungsraum wie beabsichtigt agiert [DIN22989, S. 36]. Automatisierte Systeme bilden eine Vorstufe, welche noch nicht losgelöst vom Bediener operieren [KGK23, S. 86]. Diese werden unter anderem durch Prescriptive Analytics befähigt [HKS+22, S. 17, BWS23, S. 337, DEG+20, S. 5].

**Bedeutung im Kontext der Ausarbeitung:** Aus dem breit akzeptierten Reifegradmodell nach ACATECH lassen sich einige Implikationen für die Ausarbeitung ableiten. Prescriptive Analytics Use Cases zählen auf Stufe fünf und sechs des Reifegradmodells ein. Dies

bedingt aber auch, dass wenigstens partiell im Kontext der Produktion die Reifegradstufen eins bis vier erreicht sein müssen. Weiterhin wird klar, dass neben einem übergreifenden Assessment der Reife auch eine spezifische Betrachtung der Teilaspekte der Produktion nötig ist (Use Cases, Analytics Komponenten und Daten-Infrastruktur).

### 2.2.3 Industrie 4.0 Daten-Infrastruktur

Mit der Vision der Industrie 4.0 rückt die **Daten-Infrastruktur** in den Fokus. Diese baut im Ist-Stand in produzierenden Unternehmen in der Regel auf der Automatisierungspyramide auf [DGK+15, S. 15]. In der Literatur wird primär Bezug genommen auf die klassische Automatisierungspyramide gemäß EN IEC 62264-6:2022 [DIN62264-6]. Es gibt viele verschiedene Ausprägungen der Automatisierungspyramide welche marginal voneinander abweichen [MPM17]. Leicht variierende Nomenklaturen und Anzahlen an Ebenen fassen aber übergreifend dieselben Sachverhalte zusammen [MPM17, S. 2]. Im Folgenden wird eine detailliertere aber auf der Automatisierungspyramide aufbauende Version nach DUMITRESCU ET AL. als Referenz herangezogen (vgl. Bild 2-5) [DGK+15].

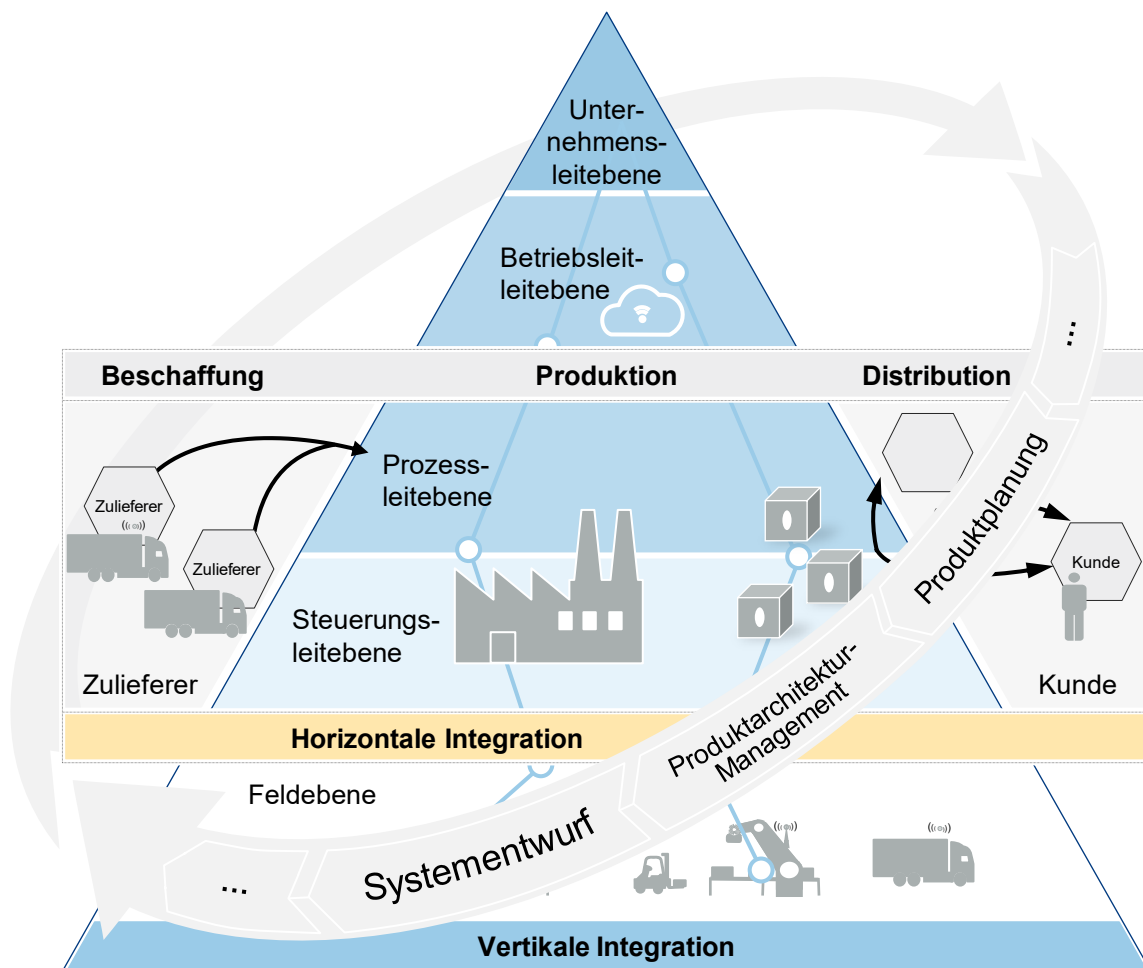


Bild 2-5: Industrie 4.0 Daten-Infrastruktur mit Fokus auf die horizontale, vertikale und lebenszyklusbezogene Vernetzung von Daten nach DUMITRESCU ET AL. [DGK+15, S. 15]

Auf unterster Ebene (**Feldebene**) wird der Produktionsprozess selbst verortet (Level 1). Die **Steuerungsleitebene** (Level 2) beherbergt speicherprogrammierbare Steuerungen und andere echtzeitfähige Steuerungssysteme. Sie steuert den Produktionsprozess über Sensoren und Aktoren der Feldebene [DGK+15, S. 15]. Der flächendeckende Einsatz von Sensorik und automatisierten Systemen erlaubt eine genauere Echtzeitbeschreibung der Produktionsumgebung. Die vorliegenden Daten können zu einer erhöhten Qualität von Entscheidungsprozessen und -ergebnissen führen [GGT23, S. 385]. In der **Prozessleitebene** (Level 3) wird mithilfe von Mensch-Maschine-Schnittstellen und Supervisory Control and Data Acquisition Systemen der spezifische Produktionsprozess angeleitet und überwacht [DGK+15, S. 15]. Die **Betriebsleitebene** aggregiert Informationen und stellt sie in Systemen wie den Manufacturing Execution Systemen zur Verfügung (Level 4). Die oberste Ebene ist die **Unternehmensleitebene** [DGK+15, S. 15]. Diese auch Topfloor genannte Ebene wird von Systemen wie Enterprise Resource Planning Systemen gefüllt (Level 5). Diese Systeme dienen der Verarbeitung der geschäftsrelevanten Daten. [MPM17, S. 7, Sie16, S. 49, DGK+15, S. 15]

**Drei zentrale Vernetzungsaktivitäten** im Kontext der Daten der Produktion auf dem Weg hin zur Industrie 4.0 sind hervorzuheben. Dazu zählen die horizontale und vertikale Integration von Systemen und Datenströmen sowie das umfassende Systems Engineering [DGK+15, S. 15]. Die **horizontale Integration** beschreibt die Vernetzung über die Steuerungs- und Prozessleitebene im Kontext der Beschaffung und Distribution zu anderen Unternehmen oder Entitäten hin. Sie ermöglicht schnelle Reaktionszeiten bei Änderungen und eine dezentrale und flexible Produktion [DGK+15, S. 13]. Kern der **vertikalen Integration** ist die Verknüpfung von IT-Systemen über Hierarchieebenen hinweg. Hauptvorteil dieses Integrationsbestrebens ist eine Möglichkeit zur Synchronisierung von Geschäftsprozessen und Abläufen über verschiedene Unternehmen hinweg [DGK+15, S. 13, KWH+12]. Die Perspektive des **umfassenden Systems Engineering** verfolgt einen Lebenszyklusgedanken. Weitere Daten kommen aus der Produktentstehung und Nutzung hinzu. Diese können implizit auf allen Ebenen ereignisbasiert zur Verfügung gestellt werden. Im Rahmen der Lebenszyklusbetrachtung sind Prozesse wie die Produktplanung, das Produktarchitekturmanagement und der eigentliche Systementwurf mögliche Datenquellen [DGK+15, S. 14].

Die Vernetzungsaktivitäten führen zu einem langsamen Aufbrechen der Automatisierungspyramide [MPM17, S. 7]. Durch Konzepte aus dem IoT entstehen Bypässe, welche singuläre Lösungen mit einer direkten Vernetzung und Verlagerung von Teilfunktionen in die Cloud ermöglichen. Es geht selten darum, vorhandene Systeme zu ersetzen. Vielmehr wird der starre Handlungsrahmen durch eine netzartige Struktur ersetzt. In welchem Maße die Automatisierungspyramide aufbricht, bleibt abzuwarten [MPM17, S. 7].

**Bedeutung im Kontext der Ausarbeitung:** Aus den Grundkonzepten der mehrdimensionalen Vernetzung innerhalb der Automatisierungspyramide ergeben sich eine Reihe von Potenzialen zur effizienten Analyse von Daten. Mithilfe der Vernetzung werden neue Analytics Use Cases möglich, welche aus dem Blickwinkel der Prescriptive Analytics

genauer analysiert werden müssen. Weitere Implikationen ergeben sich für die Voraussetzungen der Konzeption von Prescriptive Analytics Use Cases. Existierende IT-Systeme sind vorhanden und müssen berücksichtigt werden. Die Zugänglichkeit von Daten ist immer noch abhängig vom Industrie 4.0 Reifegrad innerhalb der Produktion.

#### 2.2.4 Status Quo und Herausforderungen in der Umsetzung

Viele produzierende Unternehmen haben Use Cases bisher in den ersten vier Reifegradstufen des ACATECH Reifegradmodells umgesetzt (vgl. Kapitel 2.2.4) [GBW22]. Jedoch existiert eine Lücke zwischen Versprechen und umgesetzten Konzepten der Industrie 4.0 [Rei17]. Im jetzigen Umsetzungsstand werden insbesondere aus historischen Daten nur wenig Erkenntnisse abgeleitet. Das wird primär darauf zurückgeführt, dass das Konzept der Industrie 4.0 viel eher als Befähiger für die Umsetzung davon losgelöster Initiativen (basierend auf geschaffener Transparenz) zu sehen ist [NHQ+17, S. 47].

Zum Erfolg des Konzepts der Industrie 4.0 gibt es aufgrund fehlender statistischer Maße und Kennzahlen zur unabhängigen Evaluation wenig quantitative Evidenz [Aue18, S. 2]. Der jetzige Implementierungsfortschritt wird in einer Reihe von qualitativen Use Case zentrierten Studien näher beleuchtet. Studienübergreifend wird ein steigender Grad an Digitalisierung festgestellt [Del16, GBW22, Aue18, LPR+23, Sie23, McC24]. Folgende qualitativ begründete **Herausforderungen in der Umsetzung** prägen die anwendungsorientierte Betrachtung des Konzepts der Industrie 4.0:

- **Hemmnisse bei der Digitalisierung** liegen durch einen eindimensionalen Blick auf IT als Kostenfaktor vor. Dementsprechend investieren viele Unternehmen nicht ausreichend in die Digitalisierung der Produktion [KR22, S. 46]. Im Kontrast dazu steht, dass dem demografischen Wandel und Fachkräftemangel durch die Nutzung der zunehmenden Digitalisierungs- und Automatisierungsoportunitäten begegnet werden soll [Pfe17, S. 108, Aue18, RBD+17, S. 67].
- Die steigende Menge an auswertbaren Daten, bei fehlendem Wissen über die Relevanz der Daten, sorgt für weitere **Hemmschwellen bei der Umsetzung** von Industrie 4.0 Use Cases [HJB21, S. 195, KGK23, S. 13].

**Bedeutung im Kontext der Ausarbeitung:** Im Ist-Stand werden siloartige Umsetzungen forciert. Es werden keine Verbindungen zur übergeordneten Vernetzung forciert. Oftmals fehlen diese komplett. Use Cases werden primär technologie- und wenig strategiegetrieben ausgewählt [Del16]. Wenn diese strategiegetrieben ausgewählt werden, dann meist aus monetär bewerteten Gesichtspunkten. Die generellen Voraussetzungen für den effizienten Einsatz von Data Analytics in der Produktion wurden geschaffen. Im Detail scheidet es noch an der konkreten Umsetzung und ganzheitlichen Perspektive.

## 2.3 Industrial Data Science für die Produktion

Als Teilmenge eines Industrie 4.0 Use Cases sind Use Cases mit unmittelbarem Bezug zur Optimierung und Analyse der Produktion zu sehen. Im Rahmen dieser Use Cases können im Besonderen die Data Science basierten Use Cases betrachtet werden [BHF+23]. Die Bedeutung der **Industrial Data Science für die Produktion** zur Optimierung und Effizienzsteigerung von produzierenden Unternehmen nimmt stetig zu [DWS22, S. 10, RRH+24, S. 438]. Dies liegt primär an der zunehmenden Komplexität in Produktionsumgebungen, welche von traditionellen Ansätzen nicht mehr mit vertretbarem Aufwand analysiert werden können [MBC+19, S. 5].

Zuerst wird in **Kapitel 2.3.1** ein Überblick über die Strukturierung von Industrial Data Science Use Cases gegeben. Basierend auf der Struktur werden in **Kapitel 2.3.2** die Use Case Herausforderungen und in **Kapitel 2.3.3** die Industrial Data Science Komponenten sowie Daten-Infrastruktur-Herausforderungen analysiert. **Kapitel 2.3.4** gibt einen Überblick zu den für die Entwicklung von Use Cases benötigten Rollen.

### 2.3.1 Industrial Data Science Use Case Strukturierung

Unternehmen steigern ihre Investitionen in die Datenanalyse im Produktionsumfeld stetig [McC24, S. 9, GBW22]. Insbesondere bei großen Unternehmen stehen Data Analytics und KI weit oben in der Prioritätenliste [IBM21]. Mit der Nutzung von Data Analytics für Use Cases der Industrial Data Science werden eine Reihe von versprochenen Benefits verknüpft. Dazu gehören Rationalisierung, Effizienzsteigerung sowie die Erhöhung der Innovationsfähigkeit im Produktionsumfeld [McC24, S. 11]. Diese Benefits werden in der Regel in Form von Use Cases realisiert. Nach der VDI/VDE 3714 werden Data Science Use Cases in der Regel aus drei Gründen entwickelt. Es geht darum, Daten zu beschreiben, Zusammenhänge zu erklären (hypothesengetrieben) oder Daten für fortgeschrittene Analysen zu nutzen [VDI/VDE 3714].

Existierende Optimierungsansätze der Produktion basieren in der Regel auf Strukturierung, Harmonisierung und Vereinfachung (z. B. Lean Prinzipien oder Total Productive Maintenance) [Goi19, Bru17, MWK+18]. In Industrial Data Science Use Cases (im Folgenden: Analytics Use Cases) werden Daten aus verschiedenen Quellen mit dem Zweck des Erkenntnisgewinns verknüpft. So werden Ursache-Wirkungs-Beziehungen hergestellt [RBD+17] und die im vorherigen Kapitel beschriebenen Potenziale freigelegt. Insbesondere im Produktionsumfeld gibt es eine Vielzahl unterschiedlicher Use Cases [RRK+22, S. 138]. Zur besseren **Strukturierung von Analytics Use Cases** können die damit verbundenen Elemente in Schichten unterteilt werden (vgl. Bild 2-6) [RKD17].

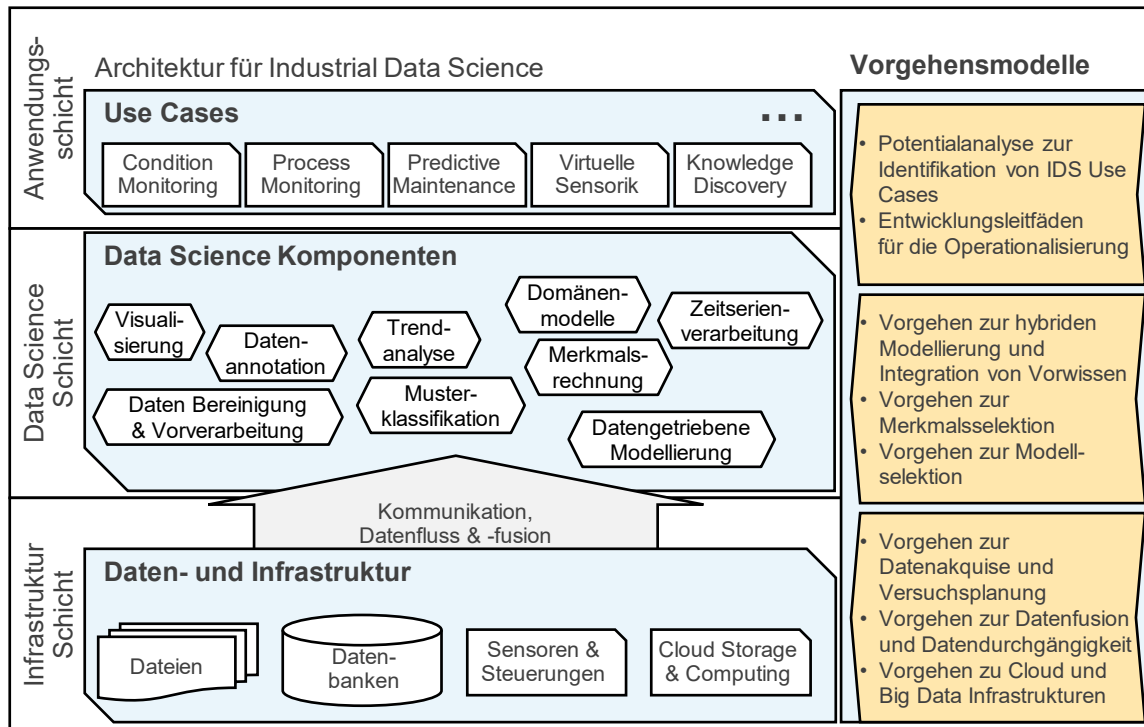


Bild 2-6: Schichtenmodell für die Industrial Data Science nach REINHART ET AL. [RKD17, S. 326]

Die **Anwendungsschicht** strukturiert mögliche Use Cases (Definition siehe Kapitel 2.1.4). In der **Data Science Schicht** werden mögliche algorithmische Bestandteile (Data Science Komponenten) gesammelt und zur Verfügung gestellt. Die genannten Beispiele beschreiben verschiedene Techniken wie die Trend-Analyse oder Musterklassifikation. Aus Sicht der **Infrastruktur Schicht** werden neben den **Kommunikations- und Datenflüssen** mögliche Datenquellen und Ressourcen gesammelt. Flankiert werden diese Schichten durch schichtenspezifische **Vorgehensmodelle** zur Planung und Entwicklung der Bestandteile sowie die Vernetzung der Schichten. Weitere Beispiele für Bestandteile der Schichten sind Bild 2-6 zu entnehmen. [RKD17]

**Bedeutung im Kontext der Ausarbeitung:** Das Schichtenmodell kann als Grundlage zur Strukturierung von Analytics Use Cases in der Produktion genutzt werden. Es betont einen ganzheitlichen Ansatz, welcher sich nicht auf eine eindimensionale Sicht fokussiert. Daher bietet es sich gut an, um dem ganzheitlichen Anspruch der Ausarbeitung mit Fokus auf die Konzeption gerecht zu werden. Im Folgenden wird das Schichtenmodell zur Strukturierung der verbleibenden Kapitel 2.3 und Kapitel 2.4 genutzt.

### 2.3.2 Analytics Use Cases

Im Folgenden wird auf Herausforderungen im Kontext der **Analytics Use Cases** eingegangen. Anwendungsfelder für Analytics Use Cases entsprechen der generellen datengetriebenen Verbesserung existierender Tätigkeiten in der Produktion (Qualitätskontrolle,

Planung und Steuerung, Entwicklung) [GFG+24, S. 17]. Aktuelle Implementierungen in der Produktion mit dem Status „Pilotphase“ konzentrieren sich auf das Wissensmanagement, die Qualitätskontrolle, die Optimierung der Instandhaltung von Ressourcen sowie die Automatisierung von Dokumentationen.

Bereits in der Nutzung sind Use Cases zur Prozessoptimierung, Maschinendatenanalyse und Qualitätskontrolle [McC24]. Zum jetzigen Zeitpunkt sind die meisten Use Cases durch die produzierenden Unternehmen selbst implementiert. Der Trend geht dahin, dass in zunehmendem Maße Zukaufösungen zur Verfügung stehen werden (Make-or-Buy Entscheidung) [LPR+23, S. 13].

Zur Übersicht über den aktuellen Problemraum an der Schnittstelle von Forschung und Praxis dient Tabelle 2-1. Diese ist angelehnt an und erweitert nach der Vorveröffentlichung nach VON ENZBERG ET AL. [EWB+24]. An der Veröffentlichung wurde maßgeblich mitgewirkt. Sie stellt eine Synthese aus Ergebnissen einer Interviewstudie sowie literaturbasierten Erkenntnissen dar. Aus der Vorveröffentlichung stammen alle folgenden strukturgebenden Tabellen. Die Tabelle baut auf dem Schichtenmodell nach REINHART ET AL. auf [RKD17].

*Tabelle 2-1: Übersicht über die Herausforderungen für Industrial Data Science in den Use Cases des Schichtenmodells aufbauend auf [EWB+24]*

Herausforderung	Kurze Erklärung und Quelle
<p style="text-align: center;"><b>Erwartungshaltungsmanagement</b></p>	<ul style="list-style-type: none"> <li>• <b>Ergebniserwartung:</b> Es werden in der Praxis in der Regel höhere Standards als bei herkömmlichen IT-Projekten (nicht datenbasierten Projekten) angelegt. Dies wird durch den Vergleich zu vollständig digitalen Unternehmen ohne die spezifischen Herausforderungen der Produktion, wie GOOGLE oder AMAZON, erschwert [NSM+20, S. 735, MVO21, S. 5].</li> </ul>
<p style="text-align: center;">Bestimmung des <b>realen Geschäftswertes</b></p>	<ul style="list-style-type: none"> <li>• <b>Geschäftswert:</b> Die Bestimmung des tatsächlichen Geschäftswerts vorab ist immer noch schwer zu erreichen [EWB+24, Jop21, S. 119, MVO21, S. 5]. Die Definition des realen Gegenwertes des Use Cases ist oftmals nicht trivial und muss über mehrere Geschäftsbereiche hinweg iterativ mit Experten entwickelt werden [NSM+20, S. 735, WWS+24, S. 3].</li> <li>• <b>Anfangsinvestitionen:</b> Der Erfolg von Analysen ist an das Wissen über die Datenqualität und die Anwendbarkeit auf die jeweilige Geschäftsfrage gebunden. Jedoch findet die Bewertung des Geschäftswertes in der Regel vor dem Sichten der Daten statt. [EWB+24]</li> <li>• <b>Mangelnde Data Analytics Kenntnisse:</b> Eingeschränktes Wissen darüber, was mit Data Analytics erreicht werden kann, hemmt den kreativen Input der Fachexperten. Mangelnde Transparenz bei der Auswahl und Priorisierung verringert ebenfalls das Engagement der Fachexperten für das Thema [EWB+24]. Nur bei einer ganzheitlichen Betrachtung von Analytics Use Cases entfalten diese ihr komplettes wirtschaftliches Potenzial [RKK+20, S. 13].</li> </ul>

Herausforderung	Kurze Erklärung und Quelle
<b>Gesamtperspektive</b>	<ul style="list-style-type: none"> <li>• <b>Technologieinduzierte Use Cases:</b> Ein Technology Push ist die in der Industrial Data Science oftmals in der Praxis dominierende Perspektive. Bisher wird zu wenig der probleminduzierte Ansatz gewählt. [NSM+20, S. 735]</li> <li>• <b>Allgemeiner Digitalisierungsgrad:</b> Die Digitalisierungsbemühungen von Unternehmen steigen stetig, aber die meisten Unternehmen müssen ihre Prozesse und Systeme noch weiter digitalisieren, um ganzheitliche Data Analytics Vorhaben zu ermöglichen. [GBW22]</li> <li>• <b>Infrastrukturkosten:</b> Use Cases lassen sich oft nicht ohne hohe Investitionen in die richtige Infrastruktur skalieren. [GBW22, SvS+24, S. 180]</li> </ul>

Für das **Erwartungshaltungsmanagement** ist insbesondere die Erwartung an direkt perfekt funktionierende Lösungen problematisch. Hierbei wird oft der Vergleich zu Digitalkonzernen gesucht, bei denen automatisch die geschäftsrelevanten Daten in den Prozessen vorliegen. Die Herausforderungen bei der **Bestimmung des realen Geschäftswertes** liegen insbesondere in der unklaren Erfolgswahrscheinlichkeit. Vorabinvestitionen für Data Analytics in Infrastruktur und Analytics Kenntnisse werden oft nicht getätigt. Hier könnte die Einflussnahme von generativer KI zur Unterstützung bei der Code Generierung zu einer weiteren Verbreitung von Industrial Data Science Fähigkeiten in den Unternehmen führen [EWB+24]. Für die **Gesamtperspektive** bei der Use Case Umsetzung sind der Fokus auf technologieinduzierte Use Cases und mangelnde Ausgaben für Infrastruktur Hemmnisse bei der Umsetzung von Analytics Use Cases in der Produktion.

**Bedeutung im Kontext der Ausarbeitung:** Viele übergeordnete Analytics Use Case bezogene Herausforderungen der Industrial Data Science sind noch ungelöst. Insbesondere die Bewertung von Use Cases zur Auswahl stellt eine Kernherausforderung dar. Dennoch bietet eine steigende Verbreitung einfacher Use Cases das Potential zum Ausbau ebendieser. Weiterhin ist eine Differenzierung vom Use Case hin zur konkreten Lösung entlang der Entwicklung wichtig.

### 2.3.3 Analytics Komponenten und Daten-Infrastruktur

Laut einer im Jahr 2020 durchgeführten Interview Studie durch NOLTE ET AL. liegt die fehlende Verbreitung von Analytics Use Cases nicht an einem fehlenden Bewusstsein für die Potenziale [NSM+20]. Vielmehr scheitern Use Cases an vielen umsetzungsrelevanten Faktoren [NSM+20, S. 734]. Zur Übersicht über diese Faktoren und weitere Herausforderungen in der Implementierung von Analytics Use Cases dienen die folgenden Tabellen. Sie adressieren Herausforderungen der **Analytics Komponenten und Daten-Infrastruktur**.

Im Bereich der **Analytics Komponenten** gibt es je Analytics Typ nach GARTNER (siehe Kapitel 2.1.3) gesonderte Herausforderungen. Tabelle 2-2 gibt einen Überblick zu den

Herausforderungen in den Analytics Komponenten, aufbauend auf dem Schichtenmodell nach REINHART ET AL. [RKD17].

Tabelle 2-2: Übersicht über die Herausforderungen für Industrial Data Science in den Analytics Komponenten des Schichtenmodells aufbauend auf [EWB+24]

Herausforderung	Kurze Erklärung und Quelle
<b>Descriptive Analytics</b>	<ul style="list-style-type: none"> <li>• <b>Dashboarding:</b> Dies stellt einen De-Facto-Standard für die meisten Produktionsunternehmen dar. Ein Schwerpunkt liegt nach wie vor auf der Zugänglichkeit für Endnutzer und Nicht-Data-Analytics-Experten.</li> <li>• <b>Zweck des Analytics Use Cases:</b> Die eigentliche Entscheidung, die auf der Grundlage eines Analyseergebnisses getroffen werden sollte, wird oft nicht in den Ansatz der Use Case Implementierung einbezogen. [HP16, GBW22]</li> </ul>
<b>Predictive Analytics</b>	<ul style="list-style-type: none"> <li>• <b>Einbindung in die IT-Systeme:</b> Analytics Lösungen performen oftmals bereits besser als die „Human Baseline“ (der menschliche Vergleich). Trotzdem sind diese schwer in die existierenden IT-Systeme einzubinden. [WRE+23]</li> </ul>
<b>Prescriptive Analytics</b>	<ul style="list-style-type: none"> <li>• <b>Integration von Entscheidungen:</b> Die allgemeine Komplexität der Automatisierung von Entscheidungen erschwert den effizienten Einsatz von Prescriptive Analytics. [KGK23]</li> <li>• <b>Algorithmen Vielfalt:</b> Bei der Entwicklung von Prescriptive Analytics Use Cases können viele verschiedene Ansätze verwendet werden. [LBA+20]</li> <li>• <b>Erweiterung der Eingangsdaten um Aktionen:</b> Zusätzlich zu den klassischen IDS- Daten müssen die möglichen Aktionen bei einer Entscheidung mit berücksichtigt werden [BUB16, S. 8].</li> </ul>
<b>Kontinuierliches Ausrollen</b>	<ul style="list-style-type: none"> <li>• <b>Ausrollen von Analytics Use Cases:</b> Die Wartung und Bereitstellung von Modellen unter Security Aspekten fällt Unternehmen besonders schwer. [RRW+22, S. 132]</li> </ul>

Bei **Descriptive Analytics** konzentrieren sich die meisten Implementierungen auf das Dashboarding und die Visualisierung. Dabei wird der Zweck der Kennzahlerfassung oft außer Acht gelassen [HP16, GBW22]. **Predictive Analytics** Teillösungen sind bisher schwer robust in die Produktion zu integrieren. Dies liegt unter anderem an der Black Box Natur der Ansätze. Darauf aufbauend galt **Prescriptive Analytics** in den letzten Jahren als noch teilweise unausgereifte Technologie [LBA+20]. Aufgrund dessen haben viele Unternehmen bisher eine Implementierung in der Praxis nicht angegangen [KGK23]. Für das **kontinuierliche Ausrollen** von Use Cases sind Unternehmen vor allem mit der Wartung und Bereitstellung von Modellen beschäftigt. Herausforderungen hier liegen in der Integration der IT-Konzepte in die existierende IT-Infrastruktur der Produktion [RRW+22, S. 132].

Neben den reinen auf Analytics Komponenten bezogenen Herausforderungen gibt es weitere in der **Daten-Infrastruktur**. Die für Industrial Data Science benötigten Daten werden im Spannungsfeld zwischen Quantität, Qualität und Investitionskosten verwaltet.

Eine optimale Verteilung im Spannungsfeld zwischen den drei Größen ist schwer zu finden [KE22, KKG23]. Weiterhin sind hohe Investitionen von Nöten, um die benötigten Daten für Data Analytics und Industrie 4.0 zu entdecken, zu analysieren und aufzubereiten [Aue18]. Vorabinvestitionen sind nötig, um Maschinen zu verbinden und eine Basisinfrastruktur für Analysen zu schaffen. Das Gleiche gilt für mögliche Werkzeuge, mit denen Data Scientists arbeiten können [EWB+24]. Ein Überblick über die relevanten Daten-Infrastruktur Herausforderungen ist in Tabelle 2-3 abgebildet. Eine ausführliche Aufschlüsselung ist Anhang A1.4 zu entnehmen.

*Tabelle 2-3: Übersicht über die Herausforderungen für Industrial Data Science in der Daten-Infrastruktur des Schichtenmodells aufbauend auf [EWB+24]*

Herausforderung	Kurze Erklärung und Quelle
Struktur industrieller Daten	<ul style="list-style-type: none"> <li>• <b>Betriebspunkte:</b> Viele Betriebspunkte mit gleichen Daten. Für eine gute Analyse werden aber verschiedene Betriebspunkte als Referenz benötigt. [CLX+22, MVO21, S. 5]</li> <li>• <b>Anreize zur Datenerzeugung:</b> Fehlende Anreize im Produktivbetrieb zum Erzeugen von Fehlerdaten. [EWB+24]</li> </ul>
Metadatenmanagement und Kontextdaten	<ul style="list-style-type: none"> <li>• <b>Vielfalt der Datenpunkte:</b> Identifikation der relevanten Daten ist herausfordernd. [Sie23, LMK21, WWS+24, S. 3]</li> <li>• <b>Filtern von Datenpunkten:</b> Zugänglichkeit von Daten und Labeln ist nicht immer gegeben. [FCW+21]</li> <li>• <b>Spezifität der Datenpunkte.</b> Übertragbarkeit der Lösungen von Maschine zu Maschine ist oft nicht gegeben [LYH+19, S. 293, MVO21, S. 5]. Die Standardisierung von Bausteinen zur Übertragung fällt schwer. [HHS24, S. 56]</li> </ul>
Variation in industriellen Daten	<ul style="list-style-type: none"> <li>• <b>Datenquellen:</b> Industriedaten zwischen verschiedenen Quellen variieren in Format, Qualität und Zugänglichkeit. [PEM+22, MVO21, S. 5]</li> </ul>
Datenmanagement von industriellen Daten	<ul style="list-style-type: none"> <li>• <b>Datennutzen:</b> Es existiert ein unklarer Datenmehrwert zum Erfassungszeitpunkt. [EWB+24]</li> <li>• <b>Datenverwaltung:</b> Data Governance bleibt aufwändig. [EWB+24, WWS+24, S. 3]</li> <li>• <b>Datenbereitstellung:</b> Datenermittlung und Verknüpfung zum Use Case ist mit hohen Aufwänden verbunden. [EWB+24]</li> </ul>

Für die Daten-Infrastruktur sind **die Struktur der Daten**, das **Metadatenmanagement** und die **Variation der industriellen Daten** zu betrachten. Weiterhin sind Aufwände in Bezug auf das **Datenmanagement** zu berücksichtigen. Die in der Daten-Infrastruktur enthaltenen Daten müssen zuerst aus den relevanten technischen Systemen oder Ressourcen extrahiert werden [KJR+18]. Dabei gilt es die Akquisition der Daten zu managen. Industriedaten weisen oft nicht die für die jeweilige Analysefrage erforderlichen Merkmale auf oder es fehlen Informationen über die Datenqualität. Dadurch steigen die Investitionskosten zur Datenbereinigung und Datenerfassung für wichtige Industriedaten stark an.

**Bedeutung im Kontext der Ausarbeitung:** Viele der technischen Herausforderungen in der Industrial Data Science sind noch ungelöst. Dazu zählt die fehlende Wiederverwendbarkeit von Lösungen und der hohe Aufwand zur Bereitstellung von ausreichend qualitativen Daten. Die Interdisziplinarität des Themenfeldes verstärkt einige Herausforderungen, die es auch im übergeordneten Feld der Data Science noch gibt.

### 2.3.4 Rollen in der Industrial Data Science

Die für die Analytics Use Case Entwicklungsaufgabe adäquate Definition von **Rollen in der Industrial Data Science** stellt einen für den Projekterfolg essenziellen Schritt dar [HBK+24]. Im Rahmen der Use Case Entwicklung gibt es verschiedenste beteiligte Akteure. Diese Akteure sind entweder direkt an der Umsetzung beteiligt oder leisten durch ihre Rolle im Unternehmen einen wichtigen Beitrag in der Planung, Konzeption und Integration der Use Cases [KJR+18, S. 164]. Das folgende Kapitel gibt einen Überblick über die essenziellsten Rollen für die Entwicklung von Analytics Use Cases. Der Überblick stellt eine Synthese aus verschiedenen Veröffentlichungen zur Entwicklung und Integration von Analytics Use Cases dar (vgl. [KJR+18, MEK+22, BSS23, KNS+23, BEF+22, SAH+22]).

Generell gibt es in der Analytics Use Case Entwicklung und späteren Nutzung verschiedene Rollen, welche zusammenarbeiten müssen [SAH+22, S. 50]. Elementare Rollen sind die **Projektsponsoren**, späteren **Nutzer**, das **Projekt- und Umsetzungsteam** sowie Rollen mit einem hohem **Befähiger** Anteil [KNS+23]. Nach MAZAROV ET AL. decken diese Rollen übergeordnete Kompetenzbereiche ab [Maz20]. Viele der genannten Rollen sind in produzierenden Unternehmen nicht klar definiert oder über mehrere Akteure verteilt [KNS+23, S. 909].

Die späteren **Nutzer** sind essenziell für die zielgruppengerechte Erhebung von Anforderungen und die Entwicklung maßgeschneiderter Lösungen für diese. Weiterhin bedarf es der Zustimmung der Management Akteure<sup>5</sup>. Je nach Unternehmen nehmen die Management Akteure verschiedene Bezeichnungen an. Dazu zählen Industrie 4.0 Manager, Digital Transformation Manager, Data Manager oder KI Manager [BEF+22, EWB+24, Cor19, S. 73]. Diese treten als übergeordnete **Projektsponsoren** auf (vgl. [BEF+22]).

Das **Projekt- und Umsetzungsteam** besteht aus Analytics Architekten, Data Scientists, Befähigern (z. B. Programmierern oder Data Engineers) und Rollen mit Domänenexpertise. Diese können aus verschiedenen Bereichen innerhalb einer Organisation stammen [BSS23, S. 13]. Der **Analytics Architekt** fungiert als Verbinder zwischen dem Umsetzungsteam und den geschäftsrelevanten Rollen (Nutzer und Projektsponsoren). Er stellt die zentrale Schnittstelle über die Bereiche und Akteure hinweg dar. Er nimmt eine orchestrierende Rolle ein und ist der Mediator zwischen Business, IT und Data Science in der Konzeption [KJR+18]. **Data Scientists** als Teil des Umsetzungsteams haben einen

---

<sup>5</sup> Mit Akteur sind Einzelpersonen gemeint. Diese Einzelpersonen können mehrere Rollen innehaben.

Fokus auf die Umsetzung von Data Analytics Projekten [Cao18, S. 4]. Sie sind federführend in allen Themen rund um Daten, Algorithmen und Implementierung [KNS+23, BSS23]. Eine Detaillierung der Anforderungen an Industrial Data Scientists kann [DWS22, S. 2, BWS23, S. 17, SSS+20, BSJ+18] entnommen werden. Als Brücke bei der Implementierung zwischen Umsetzungsteam und Domäne können **Citizen Data Scientists** unterstützen. Diese Rolle bildet aktive Domänenexperten ab, deren primärer Job außerhalb der Data Science liegt. Trotzdem weisen sie ein Mindestmaß an Kompetenz im Bereich der Data Science auf [MEK+22, Jar18, S. 584]. Als **Befähiger** gelten generelle Akteure aus dem Data Engineering und der IT [SAH+22, HMK23, KNS+23, S. 913].

Ein Ausschnitt der relevantesten Rollen ergibt aggregiert die Bereiche Management, Data Science, Domäne und IT [Maz20, SWK+24, S. 66]. Für einen tieferen Einblick in die benötigten Rollen und deren Aufgabenverteilung wird auf [KNS+23, SSS+20, BWS23] verwiesen. Je nach Unternehmen und Größe des Vorhabens sind Rollen in untergliederte Rollen aufzuteilen oder in wenigen Akteuren zu aggregieren [KNS+23, S. 915]. Diesen Rollen steht in der Realität ein Mangel an Industrial Data Science Experten [BSJ+18] gegenüber:

- Viele Unternehmen leiden allgemein unter einem Mangel an Fachkräften im Bereich Data Science. Vor allem kleinen und mittleren Unternehmen fehlt es an qualifizierten Mitarbeitern mit Data Science Kenntnissen. [CGM+16]
- Im industriellen Kontext ist der Mangel an Data Scientists laut *BAUER ET AL.* sogar noch größer, da in diesem Bereich eine Kombination von Fähigkeiten aus Informatik, Statistik und den Ingenieurwissenschaften erforderlich ist [BSJ+18]. In der Industrie gibt es nicht genug Citizen Data Scientists [MEK+22] und Data Scientists im Allgemeinen [MVO21, S. 5].

**Bedeutung im Kontext der Ausarbeitung:** Data Science muss als Unternehmensfähigkeit verstanden und gemanagt werden [Dom23]. Dazu gehört auch die richtige Zusammenstellung von Teams zur Bearbeitung der Data Science Use Cases. Die damit einhergehende Interdisziplinarität erfordert die Berücksichtigung multipler Perspektiven. Für Prescriptive Analytics als Teilbereich der Industrial Data Science folgen die gleichen Rollenprofile. Alle genannten Rollen müssen berücksichtigt werden um die Planung, Konzeption und Integration von Analytics Use Cases adäquat adressieren zu können. Eine weitere Ausdetaillierung der Rollenprofile ist kein Teil der vorliegenden Ausarbeitung.

## 2.4 Prescriptive Analytics in der Produktion

Ansätze zur Entscheidungsfindung basieren im Kern auf einer effizienten und zielgerichteten Unterstützung von Entscheidungen. Dafür werden Ansätze aus dem Technologiefeld Prescriptive Analytics verwendet. Ein Überblick über die Spezifika von **Prescriptive Analytics in der Produktion** wird im Folgenden gegeben.

Zur Erläuterung von Prescriptive Analytics in der Produktion wird auf die Strukturierung aus dem Schichtenmodell nach REINHART ET AL. zurückgegriffen [RKD17]. Auf Prescriptive Analytics Use Cases wird in **Kapitel 2.4.1** eingegangen. Die benötigten Analytics Komponenten zur Umsetzung von Prescriptive Analytics Use Cases werden in **Kapitel 2.4.2** analysiert. **Kapitel 2.4.3** gibt einen Überblick über die relevante Daten-Infrastruktur, die zur Umsetzung eines Prescriptive Analytics Use Cases benötigt wird.

### 2.4.1 Prescriptive Analytics Use Cases

Entscheidungen finden im Kontext der Produktion in verschiedenen Ausprägungen statt. Dabei können diese auf operativer, taktischer oder auch strategischer Ebene durch **Prescriptive Analytics Use Cases** unterstützt werden [Moc21, S. 163]. Das Bezugsobjekt der Entscheidung (Entscheidungsgegenstand) kann variieren [WML+23]. Neben dem Bezugsobjekt variiert auch die Entscheidungsentität (der Entscheider) [ZWD+21, S. 797f., HRH+23].

In einer Vorveröffentlichung (vgl. [WME+24]) wurden drei Use Case Fokusbereiche herausgearbeitet. Diese basieren auf einer strukturierten Literaturrecherche nach KITCHENHAM ET AL. [KPB+09]. Es wurden 35 Use Cases (Literaturschlüssel siehe Anhang A1.5) aus der Literatur auf ihre Eigenschaften hin untersucht (vgl. Bild 2-7)<sup>6</sup>:

Entscheidungsumgebung in der Produktion				
	Produktionsmanagement	Wartungsmanagement	Qualitätsmanagement	Andere
Strategisch				3 Use Case 9-11
Taktisch	1 Use Case 1-5	2 Use Case 5-8		Use Case 12
Operativ	Use Case 13-26	2 Use Case 23-32	Use Case 6, 33	Use Case 34, 35

Legende		
1	Prescriptive Produktionsplanung und Steuerung	z. B. mit Simulation von Digitalem Zwilling und Auswertung
2	Ganzheitliches Prescriptive Maintenance System	z. B. mit empfehlungsbasierten Systemen
3	Auf den Verbesserungszyklus ausgerichtete Prescriptive Analytics	z. B. mit fallbezogener Argumentation und Kausalanalyse

Bild 2-7: Prescriptive Analytics Use Cases in der Produktion [WME+24]

<sup>6</sup> Überlappende Indizes resultieren aus Veröffentlichungen, welche mehrere Dimensionen in der Produktion adressieren.

- **Fokusbereich 1 - Prescriptive Produktionsplanung und -steuerung:** Ein starker Fokus liegt auf der Vorgabe von Maßnahmen zur Anpassung der aktuellen Produktionsreihenfolge. Diese Maßnahmen betreffen in der Regel ganze Produktionsbereiche. [WME+24]
- **Fokusbereich 2 - Ganzheitliches Prescriptive Maintenance System:** Use Cases fokussieren sich auf die Vorgabe von Instandhaltungsmaßnahmen oder proaktiven Maßnahmen zur Vermeidung von Maschinenausfällen. Die Teilautonomie von Systemen im Produktionsumfeld steht häufig im Mittelpunkt. [WME+24]
- **Fokusbereich 3 – Auf den Verbesserungszyklus ausgerichtete Prescriptive Analytics:** Diese Use Cases fokussieren die Produktionsumgebung ohne operativen Einfluss auf Produktionsprozesse, Ressourcen oder Produkte. [WME+24]

Es ergeben sich eine Reihe von charakterisierenden Eigenschaften von Prescriptive Analytics Use Cases. Sie unterscheiden sich in ihrer zeitlichen Dringlichkeit der Entscheidung (Ad-Hoc bis Langzeit) [ER18, S. 11]. Der Grad der Vernetztheit und die Gültigkeit der Reichweite der Entscheidung variieren stark [WML+23]. Gleiches gilt für die Auswirkung einer einzelnen getroffenen Entscheidung [BHF+23, S. 36]. Die Ziele, Arten und Ergebnisse von Entscheidungen variieren dementsprechend auch [LBM22, S. 115]. Die Interaktionsart mit dem Entscheidungsträger (Mensch/Lösung) sorgt weiterhin für verschiedene Ausprägungen eines Use Cases [RKK+20, S. 10].

Insbesondere den Menschen durch Use Cases zu befähigen und nicht zwingend zu ersetzen, stellt einen in der Praxis etablierten Ansatz dar [HBK+24]. Die teilweise Automatisierung oder Unterstützung in Entscheidungsprozessen verspricht dabei eine geringe Abhängigkeit vom Expertenwissen der Nutzer und eine höhere Qualität der Entscheidungen in Problemlösungsprozessen in der Produktion [MKD23, S. 140]. Nach GARTNER liegt der Fokus in Zukunft auch weiterhin auf einer hybriden Entscheidungsfindung zwischen Mensch und umgesetzter Lösung [HRH+23]. Ein Ansatzpunkt ist die Unterstützung des Entscheiders durch direkte Assistenz bei den zu treffenden Entscheidungen (siehe Tabelle 2-4) [RBD+17, Gar22a].

Tabelle 2-4: Stufen der hybriden Entscheidungsfindung abgeleitet aus [Gar22a]

<b>Decision Support</b>	Humanbasiert		Beratend (Advisory)
<b>Decision Augmentation</b>	Empfehlung	Genehmigung	Veto
<b>Decision Automation</b>	Audit		Autonom

Prescriptive Analytics fokussiert sich bei der Entscheidungsunterstützung auf die Erzeugung von ausführbaren Entscheidungen auf verschiedenen Ebenen (von manuell bis voll automatisiert) [LYH+19, S. 286]. Die **Stufen zur hybriden Entscheidungsfindung werden** unterteilt in die Generierung von Insights (**Decision Support**), die Assistenz bei dem Assessment von Alternativen und die Alternativenauswahl (**Decision Augmenta-**

tion) sowie die Automation einer getroffenen Entscheidung (**Decision Automation**) [Gar22a]. Innerhalb der Stufen gibt es weitere Unterscheidungen, welche durch den Grad der Entscheidungsunterstützung charakterisiert werden (siehe Tabelle 2-4) [Gar22a]. **Humanbasierte** Systeme bieten bei der Entscheidung nur Kennzahlen als Grundlage der Entscheidung an. **Advisory** Systeme geben verschiedene Handlungsoptionen ohne Gewichtung vor. **Empfehlungssysteme** inkludieren eine Gewichtung in den vorgeschlagenen Handlungsoptionen. Systeme zur **Genehmigung** benötigen nur noch eine Bestätigung der geplanten Aktion durch den Nutzer. **Veto** Systeme handeln teilweise selbstständig mit einer Ablehnungsfunktion für den Bediener. **Auditsysteme** werden nur noch in definierten Intervallen geprüft. **Autonome** Systeme haben im gegebenen Umfeld Handlungsfreiheit [Gar22a]. Weiterhin werden Entscheidungen mit verschiedenen Zeithorizonten bei variierendem Grad der Unsicherheit getroffen (vgl. Bild 2-8).

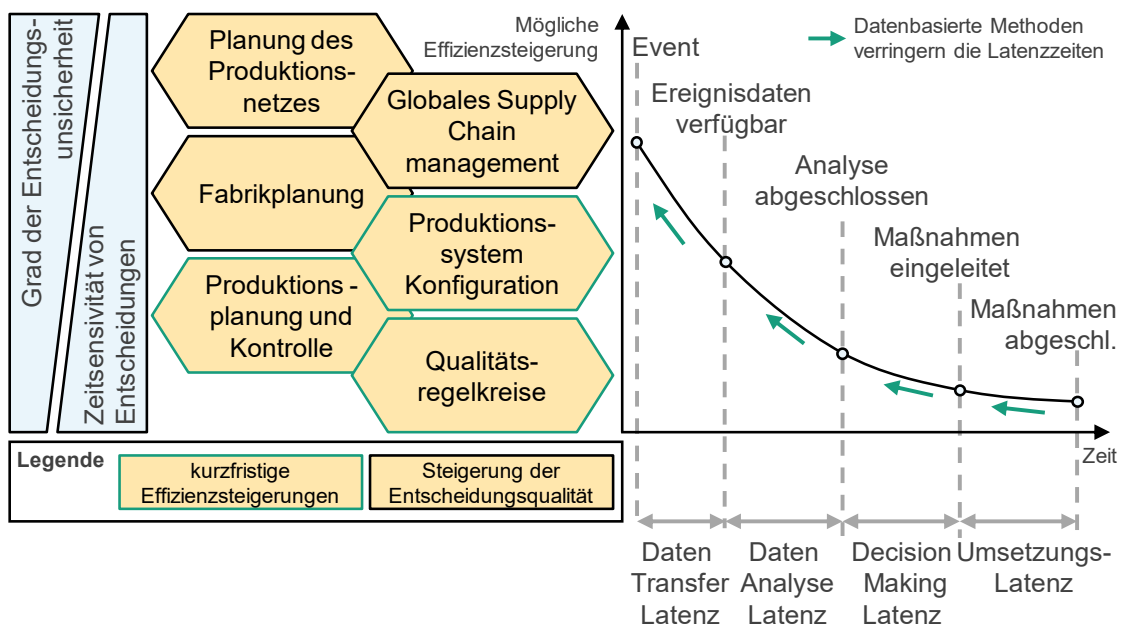


Bild 2-8: Potenziale zur Verbesserung des Produktionsmanagements mit kurzfristigem Zeithorizont in Anlehnung an [KGS+24, S. 334]

Bei einer möglichen Entscheidung bei optimaler Effizienz gibt es eine Grundmenge verschiedener Latenzfaktoren. Latenzen resultieren aus der Zeit, die zum **Datentransfer**, zur **Datenanalyse und Entscheidungsfindung (Decision Making)** sowie zur **Umsetzung der Entscheidung** benötigt wird [KGS+24, S. 334]. Der Geschäftswert einer Lösung zur Entscheidungsunterstützung hängt von der Minimierung der Zeit zwischen Event und Entscheidung ab [LBA+20, S. 58]. Weitere Hauptherausforderungen bei der Umsetzung der Prescriptive Analytics Use Cases sind in Tabelle 2-5 zusammengefasst. Die Tabelle baut auf dem Schichtenmodell nach REINHART ET AL. auf [RKD17].

Tabelle 2-5: *Spezifische Prescriptive Analytics Use Case Herausforderungen in der Produktion verortet im Schichtenmodell*

Herausforderung	Kurze Erklärung und Quelle
<b>Vernetzung der Use Cases</b>	<ul style="list-style-type: none"> <li>• <b>Insellösungen:</b> Use Case Implementierungen für Prescriptive Analytics konzentrieren sich meist auf Leuchtturm-Implementierungen und haben keine strategische Gesamtausrichtung im Blick. [IHB+18, S. 974, WZ23]</li> <li>• <b>Skalierbarkeit:</b> Es folgen Silo-Installationen und mangelnde Skalierbarkeit der implementierten Prescriptive Analytics Use Cases. [PLN+21, S. 1819]</li> </ul>
<b>Unterstützung bei der Entwicklung</b>	<ul style="list-style-type: none"> <li>• <b>Methodische Unterstützung:</b> Es liegt keine ausreichende methodische Unterstützung vor. Es besteht ein Bedarf an verallgemeinerbaren Methoden zur Entwicklung. [LBA+20, S. 67].</li> <li>• <b>Bewertung des Use Cases:</b> Metriken für eine übergeordnete Beurteilung einer Entscheidung sind schwer zu ermitteln [GT23, S. 10].</li> </ul>

Die **Vernetzung der Use Cases** scheitert bisher an de facto Insellösungen und nicht skalierbaren Use Case Konzepten. Zur **Unterstützung bei der Entwicklung** der Use Cases fehlt es weiterhin an Methodik. Dies zeigt sich insbesondere darin, dass für die Bewertung der Use Cases keine adäquaten Metriken vorliegen. Trotzdem steigt die Anzahl an möglichen Prescriptive Analytics Use Cases im Bereich der Produktion durch das Fortschreiten der Industrie 4.0 Reife (siehe Kapitel 2.2.2) stetig an [WZ24, S. 33, WME+24]. Ein weiterer Wert von Prescriptive Analytics ist die Reduzierung der kognitiven Belastung von Führungspersonen durch die Unterstützung in sich wiederholenden Entscheidungssituationen [RBD+17].

**Bedeutung im Kontext der Ausarbeitung:** Entscheidungen in der Produktion sind vielfältig, es gibt nahezu unbegrenzte Kombinationen, welche zu sinnvollen Use Cases führen können. Initial aufgebaute Prescriptive Analytics Use Cases benötigen ein Mindestmaß an formalisiertem kognitivem Entscheidungswissen. Die Wahl des Prescriptive Analytics Use Cases und des Grades an Entscheidungsunterstützung ist eine essenzielle Aufgabe bei der Konzeption eines Prescriptive Analytics Use Cases.

## 2.4.2 Prescriptive Analytics Komponenten

Konventionelle Entscheidungsunterstützungsansätze fokussieren sich primär auf strukturierte Daten und bekannte Voraussetzungen [BWS23, S. 274]. Neben problemlösungszyklusbasierten Ansätzen [MN09] werden Probleme insbesondere durch standardisierte Reports und Vorgehensweisen eliminiert [Bru17].

Zur Umsetzung von **Prescriptive Analytics** werden Analytics **Komponenten** aus dem Spektrum der Industrial Data Science verwendet. Bei der Betrachtung der Komponenten

zur Umsetzung gibt es zwei Herausforderungen. Einerseits welche Algorithmen eingesetzt werden können [LBA+20, S. 60] und andererseits welche Entscheidung vom Use Cases unterstützt werden soll [Alk23, S. 255].

Prescriptive Analytics Use Cases werden oft beschrieben oder angegangen als wären sie prädiktiver Natur [Hül21]. Dies ist dadurch bedingt, dass die Vorhersage der besten Aktion präskriptiv ist, sich aber prädiktiver Algorithmen in der Umsetzung bedient [SOL+22]. Oftmals bauen Prescriptive Analytics Ansätze auf den prädiktiven Use Cases auf [MKL+19, S. 570]. Alternativ dienen Ansätze aus der Optimierung als Grundlage für Prescriptive Analytics [FNP+19, S. 579]. Der Einsatz von reinen Machine Learning Ansätzen für Prescriptive Analytics Use Cases ist eher selten anzutreffen [LBA+20, S. 64]. Trotzdem verspricht der Einsatz von Machine Learning Ansätzen große Potenziale für die Abbildung nicht programmierbarer menschlicher Entscheidungsprozesse [EWP+24, S. 8]. Der Einsatz von Sprachmodellen für Entscheidungsprozesse wird in ersten Studien erforscht, ist aber noch nicht etablierter Bestandteil des Forschungsfeldes (vgl. [JCL+23, Tho23]). Weitere **Haupt Herausforderungen** in den Prescriptive Analytics Komponenten sind in Tabelle 2-6 zusammengefasst. Die Tabelle baut auf dem Schichtenmodell nach REINHART ET AL. auf [RKD17].

Tabelle 2-6: *Spezifische Prescriptive Analytics Komponenten Herausforderungen in der Produktion verortet im Schichtenmodell*

Herausforderung	Kurze Erklärung und Quelle
<p><b>Algorithmenvielfalt</b></p>	<ul style="list-style-type: none"> <li>• <b>Übertragbarkeit auf die Produktion:</b> Techniken sind teilweise noch nicht ausgereift für eine breite Anwendung in der Industrie. Für eine Analyse der anwendbaren Techniken wird auf [LBA+20, S. 68, KC21, S. 1] verwiesen. Neben dem Trend der Modularisierung liegt auch der Trend des End-to-End Lernens in Machine Learning Anwendungen vor [LBA+20, S. 64].</li> <li>• <b>Integration von kognitiven Komponenten:</b> Spezifische Ziele und Strategien können nur schwer in existierende Algorithmen integriert und kontextbasiert berücksichtigt werden [LYH+19, S. 293]. Die allgemeine Komplexität der Automatisierung von Entscheidungen erschwert den effizienten Einsatz von Prescriptive Analytics [KKG23].</li> </ul>
<p><b>Erweiterung der Eingangsdaten um Aktionen</b></p>	<ul style="list-style-type: none"> <li>• <b>Entscheidungen unter Unsicherheit:</b> In der Realität wird ohne perfekte Informationslage entschieden [TBH20, S. 876, Sim60]. In Entscheidungsprozessen wird daher oft mit nur den Umständen entsprechender Optimalität vorliebgenommen [LYH+19, S. 286]. Dies stellt den pragmatischeren Ansatz dar, da Entscheidungen in Unternehmen oft rasch und unter unvollständiger Informationslage getroffen werden [Hül21, Sim60].</li> <li>• <b>Aktionen als zusätzliche Eingangsdaten:</b> Ergänzend zu den klassischen IDS-Daten müssen die möglichen Aktionen bei einem Algorithmus für Entscheidungen mit berücksichtigt werden [BUB16, S. 8].</li> </ul>

Herausforderung	Kurze Erklärung und Quelle
<p style="text-align: center;"><b>Integration von Entscheidungen</b></p>	<ul style="list-style-type: none"> <li>• <b>Analytics Verkettung:</b> Die Eingabedaten können aus anderen Analytics Use Cases wie Diagnose, Optimierung oder Vorhersage stammen. Diese Kombination schafft zusätzliche Unsicherheitsfaktoren bei entscheidungsrelevanten Daten. [Hül21, Jar18, S. 584, LBA+20, S. 67]</li> <li>• <b>Abhängigkeit von anderen Use Cases:</b> Hoher Grad an Unsicherheit bei Ursache-Wirkungs-Beziehungen und deren Entscheidungsdaten in den Produktionsbereichen [MKD23, S. 141].</li> </ul>

Prescriptive Analytics ist per se als Technologiefeld und weniger als Algorithmenklasse zu betrachten. Das Technologiefeld bedient sich etablierter Techniken mit der Zielstellung Handlungsempfehlungen im Kontext der datengetriebenen Entscheidungsfindung zu geben [WZ24, S. 43]. Insbesondere wenn die Entscheidung unstrukturiert ist oder die Voraussetzungen dynamisch sind, bietet es sich an, Methoden des Machine Learnings in Erwägung zu ziehen [KC21, S. 1]. Die Reife und **Vielfalt der Algorithmen**, welche zur Verfügung stehen, variieren stark. Zusätzlich wird der **IDS-Datenraum um Aktionen erweitert**. Dabei spielt das Thema der Unsicherheit in verschiedenen Dimensionen eine Rolle. Unsicherheit liegt vor in der Aktion, dem Handlungsrahmen, der Qualität der zugrundeliegenden Entscheidungsdaten sowie der Vorhersage zukünftiger Ereignisse [KGS+24, S. 338]. Diese Ebenen können sich durch das Bezugsobjekt (Produkt, Prozess, Ressource [HFR+99]) oder die Entscheidungsebene (systemübergreifend, System, Sub-System [SMF18, S. 596]) unterscheiden [WML+23]. Die **Integration von Entscheidungen** ist eine doppelte Herausforderung. Neben der Verkettung mit anderen Prescriptive Analytics Use Cases ist auch die Abhängigkeit von Use Cases der Diagnose und der Prädiktion zu betrachten. Um diesen Herausforderungen zu begegnen, gibt es drei übergeordnete Paradigmen: Existierende Algorithmen verbessern, Algorithmen an die Domäne anpassen oder speziell für die Domäne entwickeln [GGT23, S. 387].

**Bedeutung im Kontext der Ausarbeitung:** Die vorgestellten Analytics Komponenten bilden die Grundlage zur Umsetzung. Im Folgenden werden diese als Kontextwissen berücksichtigt. Es bleibt festzuhalten: Es gibt zur Implementierung von Prescriptive Analytics viele verschiedene Ansätze, welche teilweise aufeinander aufbauen oder verschachtelt werden können. Es resultiert eine Komplexität in Zusammenhang mit den eingebetteten Use Cases. Viele existierende Analytics Ansätze werden aufgegriffen und um eine Entscheidungskomponente angereichert. Die Umsetzung von Prescriptive Analytics ist durch die enge Verzahnung mit Entscheidungen herausfordernd.

### 2.4.3 Prescriptive Analytics Daten-Infrastruktur

Prescriptive Analytics in der Produktion kann datengetrieben, modellgetrieben oder wissensgetrieben umgesetzt werden. Hybride aus diesen Ansätzen sind denkbar. Auch wenn diese Ansätze in ihrem Wirkprinzip variieren, benötigen sie alle als Grundlage Daten zur

Erstellung oder zum Betrieb [BLA+21]. Neben strukturierten Daten spielen auch insbesondere unstrukturierte Daten<sup>7</sup> eine Rolle [WZ23, S. 7]. Um isolierte Entscheidungen zu vermeiden, ist eine vertikale und horizontale Vernetzung der Daten für Prescriptive Analytics Use Cases in der **Daten-Infrastruktur** nötig (siehe Kapitel 2.2.1) [WZ23].

Die **Haupt Herausforderungen** in der Daten-Infrastruktur für Prescriptive Analytics in der Produktion sind in Tabelle 2-7 zusammengefasst. Die Tabelle dient als Überblick. Sie baut auf dem Schichtenmodell nach REINHART ET AL. auf [RKD17].

Tabelle 2-7: *Spezifische Prescriptive Analytics Daten-Infrastruktur Herausforderungen in der Produktion verortet im Schichtenmodell*

Herausforderung	Kurze Erklärung und Quelle
<p><b>Zugänglichkeit der Daten</b></p>	<ul style="list-style-type: none"> <li>• <b>Dokumentation:</b> Prescriptive Analytics Daten sind Bestandteil von Entscheidungen und werden oft nicht dokumentiert oder gekennzeichnet. [BUB16, S. 9]</li> <li>• <b>Formalisierungsgrad:</b> Daten sind oft verfügbar Eine der größten Herausforderungen ist jedoch ihre Zugänglichkeit und der fehlende Überblick über die Daten [MKD23, BUB16]. Das Potenzial von Entscheidungsdaten wird noch immer nicht voll ausgeschöpft. Oft werden Daten über Entscheidungen entweder nicht formalisiert oder nicht analysiert. [MKD23]</li> <li>• <b>Kontrafaktische Überlegungen:</b> Es liegt ein allgemeiner Datenquellenmangel vor, wenn es um entscheidungsspezifische Daten geht [LYH+19, S. 293]. In der Regel werden keine kontrafaktischen Überlegungen angestellt, das heißt es gibt keine "Was-wäre-wenn-Daten" für Entscheidungen, die nicht getroffen wurden [BUB16, S. 14, SOL+22]. Dementsprechend sind die Folgen in der Realität oft so komplex, dass ein Modell oder Algorithmus dies nicht direkt abbilden kann [SOL+22].</li> </ul>
<p><b>Datenqualität</b></p>	<ul style="list-style-type: none"> <li>• <b>Historische Daten:</b> Die Information zur Qualität von historischen Daten einer Entscheidung ist eine bestehende Herausforderung bei der Umsetzung von Prescriptive Analytics Use Cases. [BUB16]</li> <li>• <b>Entscheidungsdaten:</b> Die Qualität der Prescriptive Analytics Daten ist meist mangelhaft [Alk23, S. 255]. Dies gilt insbesondere für Entscheidungsdaten, die auf menschlichen Entscheidungsprozessen wie Qualitätsprüfungen oder Qualitätsberichten basieren. [LBH+21, MKD23, S. 141]</li> <li>• <b>Datendrift bei Prescriptive Analytics Daten:</b> Der Drift kann in der Semantik der Daten oder in der Verteilung der Daten an sich liegen (Konzept Drift und Daten Drift). Ein semantischer Drift beschreibt eine Veränderung in der Bedeutung der Daten. Ein Drift der Daten an sich bedeutet, dass sich die allgemeine Art, Menge oder Häufigkeit der beobachteten Variable ändert [KC21, S. 4].</li> </ul>

<sup>7</sup> Beispiele hierfür sind Dokumente, welche präskriptive Informationen enthalten – zum Beispiel FMEAs oder 8D-Reports (vgl. [TTX+04, KHK+20, MKD23])

Die **Zugänglichkeit der Daten** in der Produktion für eine datengetriebene Entscheidungsfindung ist eine Herausforderung. Durch die in Kapitel 2.2.4 beschriebene variierende Industrie 4.0 Reife in der Produktion weicht auch die Grundlage an zur Verfügung stehenden Daten ab. Die bereitgestellten Daten müssen weiter verfeinert und als Grundlage für Entscheidungsprozesse aufbereitet werden [NHQ+17, S. 47]. Insbesondere die Auswahl aussagekräftiger Daten ist in der Praxis schwierig [KGK23, S. 149]. Es bleiben in der Realität viele aufgenommene Daten ungenutzt und werden nicht für etwaige Entscheidungsprozesse zu Rate gezogen [NHQ+17, S. 47]. In der Praxis scheitert es noch an der ganzheitlichen Integration von Daten aus verschiedenen angrenzenden Prozessen (siehe Kapitel 2.2.3) [WH22]. Dem zugrunde liegt immer eine Abwägung zwischen Kosten zur Datenerhebung und dem möglichen Mehrwert der Daten [KE22, S. 18]. Dies liegt unter anderem an einer allgemeinen Knappheit von relevanten Entscheidungsdaten [KC21, S. 4]. Je nach betrachtetem Use Case variieren die möglichen vorhandenen Eingangsdaten stark [SZ18]. Diese können aus vorherigen Analytics Anwendungen oder der direkten Umgebung des Use Cases stammen [NMW+24, S. 8]. Weiterhin liegen Daten oftmals in Silos vor [KGK23, S. 149].

Es existiert eine Lücke in Unternehmen im deutschsprachigen Raum zwischen dem gefühlten Bedarf an qualitativen Daten und der eigentlichen Investition in die Erzeugung dieser [BUB16, S. 127]. Die Veränderlichkeit der **Datenqualität** von Datenströmen und die inhärenten Änderungen der Daten (Drift) verstärken dieses Phänomen [KC21, S. 4]. Die Messung der Qualität von Entscheidungen stellt einen aktuellen Forschungsgegenstand dar (vgl. Konzept der Bounded Rationality, Anhang A1.2) [BUB16, S. 130]. Die Qualität von getroffenen Entscheidungen bei der Entscheidungsfindung und die Bewertung von Entscheidungsprozessen ist eine große Herausforderung. Die Qualität von Entscheidungen korreliert dabei nicht zwangsläufig mit der Menge an zur Verfügung stehenden Daten [BUB16, S. 130]. Vielmehr gilt es, jeden Entscheidungskontext genau zu analysieren.

**Bedeutung im Kontext der Ausarbeitung:** Was Prescriptive Analytics Use Cases von anderen Use Cases unterscheidet, ist, dass weitere Daten aufbauend auf anderen Use Cases benötigt werden. Dies erhöht die Komplexität des Vorhabens und macht eine systematische Herangehensweise unabdingbar. Weiterhin sind die für Prescriptive Analytics benötigten Daten oftmals noch nicht strukturiert erschlossen oder werden in existierenden Data Analytics Konzepten nicht hinreichend mitbedacht. Nicht zu verachten sind Aufwände bei der Einführung der Use Cases. Dazu zählen neben der Integration der Use Cases in die IT-Infrastruktur [Sie23] auch die Sensibilisierung der Mitarbeiter für das sich ändernde Arbeitsumfeld [GBB+23].

## 2.5 Entwicklung von Prescriptive Analytics Use Cases

Die **Entwicklung von Prescriptive Analytics Use Cases** wird oftmals als reines IT-Projekt missverstanden. Entsprechende Herausforderungen im Kontext der Organisation, der

technischen Bedarfe und des Geschäftszweckes werden nicht adäquat adressiert [IHB+18, S. 974]. Da Prescriptive Analytics Use Cases eine Teilmenge von Analytics Use Cases darstellen [Cao18], werden diese im Folgenden nicht gesondert hervorgehoben. Alle herausgearbeiteten Herausforderungen in der Analytics Use Case Entwicklung werden durch die für Prescriptive Analytics spezifischen Charakteristika (siehe Kapitel 2.4) verstärkt. Zur Analyse der verschiedenen Ebenen zur Entwicklung von Prescriptive Analytics Use Cases wird die folgende Struktur genutzt.

Zuerst wird ein Überblick über den Gesamtprozess der Entwicklung von Analytics Use Cases in **Kapitel 2.5.1** gegeben. Darauf aufbauend werden die existierenden Herausforderungen bei der Identifikation von Analytics Use Cases in **Kapitel 2.5.2** beleuchtet. Die Planung von Analytics Use Cases wird in **Kapitel 2.5.3** beschrieben. **Kapitel 2.5.4** gibt einen Einblick in das Enterprise Architecture Management für die Produktion. Die Schritte der Konzeption sowie Implementierung (Integration und Umsetzung) von Analytics Use Cases werden in **Kapitel 2.5.5** und **Kapitel 2.5.6** analysiert.

### 2.5.1 Strategiekonforme Entwicklung von Analytics Use Cases

Industrie 4.0 Use Case Entwicklungsvorhaben scheitern oftmals an einer fehlenden Verbindung zwischen strategischer, taktischer und operativer Ebene [IHB+18, S. 974]. Aus methodischer Sicht konzentrieren sich Vorgehensmodelle zur Entwicklung in der Regel entweder auf eine Use Case spezifische Perspektive (z. B. [HWS+19]) oder den strategischen übergeordneten Kontext. Im Kern sollte die **strategiekonforme Entwicklung von Analytics Use Cases** stehen (z. B. [Rot16, KML+19]). Eine Übersicht zu den Phasen der Entwicklung von Analytics Use Cases kann Bild 2-9 entnommen werden.

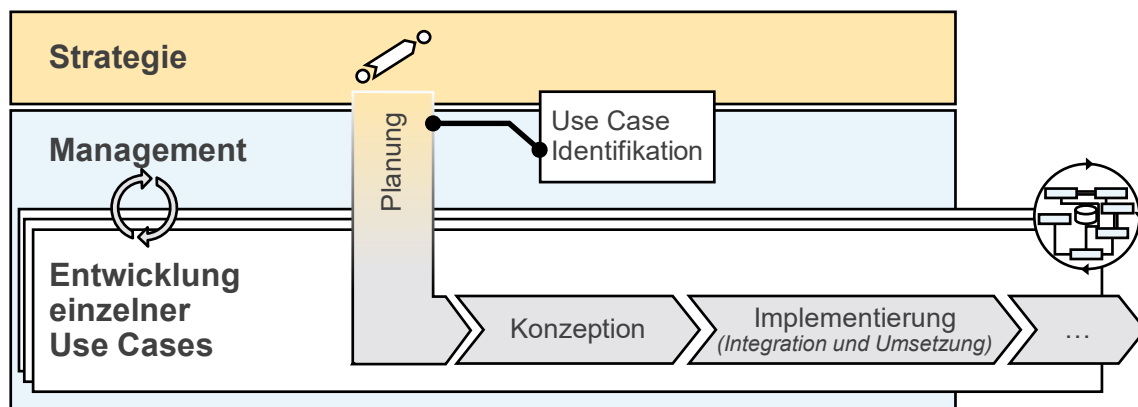


Bild 2-9: Analytics Use Case Entwicklung in der Produktion [WMK+24]

Zu allen Analytics Use Case Entwicklungen sollte eine Angleichung mit einer unternehmensspezifischen Daten-, KI- oder Analytics **Strategie** angestrebt werden [Grö22]. Das Konstrukt der Datenstrategie und deren Instanziierung für produzierende Unternehmen stellt einen aktuellen Forschungsgegenstand aus der Domäne der Wirtschaftsinformatik dar [Grö22]. Der Bedarf für eine Datenstrategie leitet sich aus dem Umstand ab, dass die Extraktion zielgerichteter Erkenntnisse aus Daten keine triviale Aufgabe ist [LMK21,

SDD+17]. Unternehmensübergreifend müssen strategisch abgestimmte Voraussetzungen, Standards und Systeme etabliert werden, um aus großvolumigen Datenvorkommen Erkenntnisse ableiten zu können [LMK21]. Die Hauptaufgabe des **Managements** ist die Sicherstellung der Synchronisation zwischen den einzelnen Entwicklungsvorhaben.

Aus einer Analytics Strategie des Unternehmens wird die **Entwicklung** von Analytics Use Cases angestoßen. Die Entwicklung beginnt mit der Use Case **Planung** durch eine initiale Use Case **Identifikation** [WMK+24]. Die Planung beinhaltet nach WÖHE ET AL. die Annäherung an die günstigste Alternative durch Abwägen verschiedener Handlungsalternativen vor der eigentlichen Entscheidung [WDB13, S. 140]. Nach erfolgreicher Planung einer definierten Menge an Use Cases werden diese konzeptioniert [WMK+24]. Die **Konzeption** beschreibt nach EHRENSPIEL den Vorgang, bei dem ein Überblick über die prinzipielle Funktionsweise eines Systems erlangt wird [Ehr09, S. 251]. Zur Konzeption von Analytics Use Cases gibt es im Kontext der Produktion kein einheitlich definiertes und übergeordnetes Vorgehen. Der Schritt ist dennoch essenziell, um die wichtigste Phase der Entwicklung (Domänenverständnis) zu unterstützen [HBK+24]. In der darauffolgenden **Implementierung** werden die Konzepte **umgesetzt** und in die Unternehmensarchitektur **integriert**. Die Integration ist dabei definiert als Verknüpfung von verschiedenen IT-Systemen mit wenigen Schnittstellen [Dud24-ol]. Die finale Umsetzung ist durch den oben beschriebenen iterativen Charakter geprägt [WMK+24].

Das beschriebene Vorgehen ist idealtypisch und selten in vollem abgebildetem Umfang in der Praxis anzutreffen. HARTMANN ET AL. heben insbesondere für die Analytics Use Case Projekte hervor, dass diese einen kontinuierlichen Charakter (durch Wartung und Betrieb) aufweisen [HBK+24]. Bei der **Entwicklung und dem Betrieb von Data Analytics Use Cases** liegt eine prävalente Herausforderung in den gegensätzlichen Herangehensweisen von Stakeholdern in Data Analytics Projekten vor. Managementansätze sind oft prozedural, wohingegen IDS Ansätze eher iterativer Natur sind [HMS+23, S. 4]. Es existiert eine Nichtübereinstimmung zwischen der managementgetriebenen Perspektive (stufenweise planbare Projekte) und der Data Science Perspektive (iterativ, unsicher, geprägt von Experimenten) [HMS+23, S. 2]. So ergibt sich eine Hauptherausforderung bei der aktuellen Herangehensweise für die Entwicklung von Analytics Use Cases: Eine starke Fokussierung auf die Entwicklung einzelner nicht vernetzter Analytics Use Cases [EWB+24].

**Bedeutung im Kontext der Ausarbeitung:** Das hier beschriebene übergeordnete Vorgehen dient als Überblick zur Struktur der nun folgenden Unterkapitel. Für die Planung, Konzeption und Integration von Prescriptive Analytics Lösungen gilt es das übergeordnete Vorgehen anzupassen und zu detaillieren. Dabei wird mit dem Begriff der Integration im Folgenden die Prüfung der Integrierbarkeit beschrieben. Es wird nicht die finale Umsetzung der Integration in diesem Schritt inkludiert.

## 2.5.2 Identifikation von Analytics Use Cases für die Produktion

Zur **Identifikation von Analytics Use Cases für die Produktion** gibt es verschiedene Treiber und Informationsquellen. Informationsquellen können unternehmensinterner und -externer Natur sein [KML+19]. Auf die Treiber von Analytics Use Cases wird im Folgenden genauer eingegangen:

- **Potenzialinduziert (intern):** Potenzialinduzierte Analytics Use Cases haben einen vorher bekannten Geschäftsnutzen im konkreten Anwendungsszenario als Treiber [JEK+19, MMF+20]. Ein Beispiel ist die Anwendung von Analytics zur präziseren Bestimmung von Durchlaufzeiten (vgl. [WRE+23]). Dies führt direkt zu einer Steigerung der Maschinenauslastung [WRE+23].
- **Hypotheseninduziert (intern):** Hypotheseninduzierte Analytics Use Cases dienen der Beantwortung von klaren Fragen aus dem Geschäftsbereich. Diese treten in der Regel einmalig auf und werden durch den Geschäftsbereich direkt aufgeworfen. [VDI/VDE 3714, S. 6, PME+22]
- **Referenzinduziert (extern):** Referenzinduzierte Analytics Use Cases werden durch eine erwiesene Machbarkeit oder ein vorteilhaftes Aufwand-Nutzen-Verhältnis und der Verbreitung durch Studien von außen in eine Organisation eingebracht (klarer Geschäftsnutzen, vgl. z. B. einschlägige Studien von Beratungshäusern oder Forschungsinstituten wie [MPK+21, GBW22, MKM+19, S. 53]).

Nach einer erfolgreichen Identifikation gilt es, die relevanten Analytics Use Cases basierend auf definierten Kriterien auszuwählen [KML+19]. Dem zugrunde liegen übergreifende Mechanismen von **Push und Pull**. Für den Einsatz von neuen Technologien und Analytics Use Cases kann ein **Management Pull** vorliegen [GFG+24, S. 22]. Dies bedeutet, dass die Umsetzung bestimmter Use Cases aktiv aus dem Management getrieben wird. Alternativ kann ein **Technology Push** in die Organisation die Verbreitung von IT-Trends beschleunigen [GP14, S. 390]. Ein aktuelles Beispiel ist die rasante Entwicklung der generativen KI [GFG+24, S. 22]. Aufbauend auf den Mechanismen bilden sich die Kriterien aus einer Kombination der folgenden Faktoren:

- **Strategiegetriebene Analytics Use Cases:** Analytics Use Cases können aus strategischen Zielen und Fokusfeldern abgeleitet werden. Dieser Top down Ansatz wird von Autoren wie LIPSMEIER ET AL. und GABRIEL ET AL. [LKJ+20, GKD23] aufgrund des klaren strategischen Nutzes als vorteilhaft dargestellt. Unternehmen setzen zunehmend auf ganzheitliche Ansätze zur Verknüpfung einzelner Initiativen und Use Case Entwicklungen mit einer übergeordneten Data Analytics Strategie [EWB+24]. Dabei geben spezifische Strategien<sup>8</sup> Leitlinien für die Auswahl und Entwicklung von Use Cases in der Produktion vor [BHF+23, S. 6].

---

<sup>8</sup> Zum Beispiel kann eine Industrie 4.0-, Digitalisierungs- oder KI-Strategie im Unternehmen vorliegen. Auch wenn der Begriff der KI-Strategie nicht eindeutig definiert ist, wird dieser in der Praxis meist verwendet. Für die Inhalte einer KI-Strategie wird auf [SS21] verwiesen.

- **Technologiegetriebene Analytics Use Cases:** Analytics Use Cases können durch den Push von Technologien in den Markt in ein Unternehmen eingebracht werden. Ein Beispiel dafür sind Analytics Use Cases, die durch neueste Entwicklungen im Bereich der generativen KI möglich geworden sind [McC24]. Weiterhin gibt es Trend-Radare und Übersichten, die auf neueste Technologien mit Potenzial hinweisen [BMW22, FNP+19, HRH+23].
- **Herausforderungsbasierte Analytics Use Cases:** Eine Auswahl und Einflussanalyse kann primär auf Kosten-Nutzen-Rechnungen verschiedener Ausprägungen von Analytics Use Cases basieren. Diese kann durch die Nutzung von Key Performance Indikatoren unterstützt werden. [JLT+19, JEG+19, KML+19]
- **Opportunitätsbasierte Analytics Use Cases:** Diese können durch die Analyse der existierenden Ausgangslage und Infrastruktur ermittelt werden. Hier stehen oft Analytics Use Cases mit einem geringen Aufwand durch bereits vorliegende Daten oder IT-Systeme im Vordergrund. [MFK+22, JEK+19, BHF+23, S. 6]

**Bedeutung im Kontext der Ausarbeitung:** Die zielgerichtete Identifikation und darauf basierende Auswahl von Prescriptive Analytics Use Cases stellt eine Grundlage für die erfolgreiche Umsetzung dar. Essenziell ist es, frühestmöglich die Wirtschaftlichkeit und Zweckmäßigkeit neuer potenzieller Analytics Use Cases sicherzustellen und zu bewerten (vgl. Tabelle 2-1). Generell können Analytics Use Cases Projekte Top Down (von der Strategie aus) oder Bottom Up (vom Betrachtungsobjekt aus) geplant werden. Eine Kombination der beschriebenen Ansätze ist möglich. Wichtig ist, dass die Auswahl im Einklang mit der Strategie erfolgt [BHF+23, S. 6]. Für Prescriptive Analytics ist diese Herausforderung der Analytics Use Case Auswahl besonders groß, da nahezu jede wiederkehrende Entscheidung in der Produktion unterstützt werden könnte.

### 2.5.3 Planung von Analytics Use Cases

Analytics und KI Use Case Entwicklungsprojekte im deutschsprachigen Raum verfehlen laut einer Studie der *MHP MANAGEMENT- UND IT-BERATUNG GMBH* in über der Hälfte der Fälle (branchenübergreifend in der Industrie) den geplanten Zeitrahmen, den definierten Umfang oder das vorgesehene Budget [HHS24, S. 35]. Der Grund für den oftmals vorzufindenden Pilotcharakter von Use Cases ist eine fehlende Berücksichtigung von Aspekten außerhalb der technischen Umsetzung [HHS24, S. 35]. Dies spielt vor allem auf die Interdependenz in den Aspekten Mensch, Technik und Organisation nach *ULICH* an [Uli13, NSM+20, S. 734]. Herausforderungen bei der **Planung von Analytics Lösungen** in der Dimension Mensch und Organisation sind in Tabelle 2-8 aggregiert. Die Dimension Technik wurde bereits in Kapitel 2.4 in Form der Ebenen des Schichtenmodells adressiert.

Tabelle 2-8: Übersicht über mensch- und organisationsbezogene Herausforderungen in der Planung von Analytics Use Cases in der Produktion

Herausforderung	Kurze Erklärung und Quelle
<p><b>Projektmanagementansätze</b></p>	<ul style="list-style-type: none"> <li>• <b>Projektbearbeitung:</b> Data Scientists arbeiten in iterativen Zyklen. Das Management erwartet von Data Scientists, dass sie einem wasserfallartigen Projektmanagementansatz folgen. [HMS+23, NSM+20]</li> </ul>
<p><b>Übertragbarkeit von Use Cases</b></p>	<ul style="list-style-type: none"> <li>• <b>Silo-Installationen:</b> Die ausschließliche Konzentration auf Leuchtturm-Implementierungen haben nicht den erwarteten Geschäftswert geschaffen [MBC+19, PLN+21]. Die meisten Unternehmen zentralisieren ihr Analytics Wissen nicht durch verteilte und nicht synchronisierte Initiativen. [EWB+24]</li> <li>• <b>Skalierbarkeit:</b> Je nach analysierter Maschine können unterschiedliche Betriebsbedingungen zu unterschiedlichen Verteilungen in den Daten führen. Das macht es schwierig, Modelle, die für einen Zustand oder eine Maschine trainiert wurden, auf andere Zustände oder Maschinen anzuwenden. [ZLL+18]</li> <li>• <b>Synergieeffekte:</b> Diese können durch vernetzte Analytics Use Cases nur schwer erzeugt werden. Es findet in der Regel keine strategische Planung oder Verbindung zur Analytics Strategie des Unternehmens bei der Umsetzung statt. [PLN+21]</li> </ul>
<p><b>Multi-Domänen-Perspektive für Use Cases</b></p>	<ul style="list-style-type: none"> <li>• <b>Interdisziplinarität:</b> Die Zusammenarbeit zwischen Fachexperten und Data Scientists kann aufgrund unterschiedlicher Vorkenntnisse und Erfahrungen eine Herausforderung sein [PPW+21]. Die Interdisziplinarität von Industrial Data Science Projekten verlangt ein Mindestmaß an Fachwissen über die respektiven Bereiche. Das heißt, ein Data Scientist muss ein Grundverständnis für das Geschäftsproblem entwickeln. Ein die Geschäftssicht einnehmender Mitarbeiter muss ein Mindestmaß an Datenverständnis aufbauen. Erst diese Kombination führt zu einer erfolgreichen Kooperation. [NSM+20, S. 735]</li> <li>• <b>Bürokratie:</b> Die Analytics Werkzeuge sind für den normalen Benutzer oft nicht zugänglich. Dadurch wird die Kreativität zur niederschweligen Problemlösung durch Fachexperten unterdrückt. [EWB+24]</li> </ul>
<p><b>Übergreifendes Management</b></p>	<ul style="list-style-type: none"> <li>• <b>Projektsponsoren:</b> Mangelndes Bewusstsein und fehlende Kompetenzen, um Analyseergebnisse/Informationen zu beurteilen und damit zu arbeiten. [EWB+24]</li> <li>• <b>Ganzheitlichkeit:</b> Vielen Unternehmen fehlt ein Konzept über die technische Implementierung hinweg, welches einen Erfolg von einzelnen Implementierungen sicherstellen sollte [PBK21, S. 7].</li> <li>• <b>Management-Awareness:</b> Dem Management fehlt oft das Bewusstsein für Fallstricke in Data-Science-Projekten und es unterschätzt notwendige Iterationen und mögliche Fehlerquellen. Unternehmen neigen dazu, in spezifische und enge Analysefähigkeiten zu investieren und verpassen dabei das große Ganze. [EWB+24]</li> </ul>

Explizite ungelöste Herausforderungen liegen im Bereich der Übertragbarkeit von Analytics Use Cases, der Organisation von Multi-Domänen-Perspektiven bei der Use Case

Entwicklung, dem übergreifenden Management und verschiedenen Projektmanagementansätzen vor. Die **Übertragbarkeit von Use Cases** wird vor allem durch eine fehlende Skalierbarkeit der Lösungen, eingeschränkt genutzte Synergieeffekte und primär in Silos gedachte Umsetzungsvorhaben bedingt. Weiterhin verlassen viele Projektergebnisse nie den Pilotstatus [HHS24, S. 35]. In Bezug auf die **Multi-Domänen-Perspektive** bei der Planung sind vor allem fehlende Kompetenzen im Bereich der Fachabteilungen eine Herausforderung. Das **übergreifende Management** wird durch das Fehlen eines ganzheitlichen Konzepts bei der Implementierung vieler Einzellösungen erschwert. Dies wird durch die verschiedenen **Projektmanagementansätze** zwischen Management und Data Science verstärkt.

**Bedeutung im Kontext der Ausarbeitung:** Viele Herausforderungen resultieren aus dem Umstand, dass Analytics Use Cases als Einzellösungen geplant werden. Synergiepotenziale werden nicht genutzt und der wirtschaftliche Mehrwert bleibt durch eine fehlende Skalierbarkeit der Analytics Use Cases oft fraglich. Insbesondere im Bereich der Prescriptive Analytics sind die Aspekte der organisatorischen Verankerung und Einbettung in existierende Strukturen noch nicht hinreichend erforscht [WZ24, S. 39].

#### 2.5.4 Enterprise Architecture Management für die Produktion

Die nahtlose Integration von KI und Analytics in Produktionssysteme (und deren Architektur) stellt einen aktuellen Forschungsgegenstand dar [Aca24, S. 57]. Zur Einführung der Analytics Use Cases muss bei der Planung und dem Management die IT- und Geschäftsperspektive berücksichtigt werden [PME+22, KJR+18, Lan17, S. 79]. Dementsprechend bietet es sich an, einen architekturbasierten Blick auf die Analytics Use Cases einzunehmen. Eine mögliche Antwort für das Management von Unternehmensarchitekturen stellt die Disziplin des **Enterprise Architecture Managements** (EAM) dar. EAM beschreibt einen systematischen und ganzheitlichen Ansatz zur Planung, Konzeption und Integration von technischen Strukturen in Unternehmen [Han13, S. 144]. Es dient als Ansatz zur Brücke zwischen Geschäftsbereich und IT [Han13, S. 143]. Dabei unterstützt es das Management der Organisation und die Entscheidungsfindung bei strategischen Entscheidungen zur Organisationsentwicklung [ASM+12, S. 46]. Die Bedeutung von EAM steigt als Funktion der Größe der zu verwaltenden Unternehmens-IT-Infrastruktur [Han13, S. 144].

Die Produktion und die dazugehörigen Produktionssysteme werden zunehmend komplexer [Bau17, S. 9]. Die Methoden und Werkzeuge aus dem EAM werden für die Komplexitätsbeherrschung von Architekturen verwendet [Han13, S. 144]. Insbesondere im Bereich der produzierenden Industrie gibt es allerdings noch viele Organisationen mit einem geringen EAM Reifegrad [GAM24, S. 6].

Nach ACATECH mangelt es an Beschreibungsmodellen für Produktionssysteme und Use Cases zur Entscheidungsunterstützung zum Zwecke der Autonomie und Wandelbarkeit

[Aca24, S. 57]. Diese Beschreibungsmodelle müssen standardisiert werden und Austauschformate in andere Domänen und Systems Engineering sicherstellen [Aca24, S. 57]. Aus dem Bereich des EAM gibt es verschiedene etablierte Metamodelle zur Modellierung [Lan17, S. 79]. Diese Metamodelle werden oft auf die spezifischen Bedürfnisse des Anwendungsszenarios oder Unternehmens zugeschnitten (vgl. [LWK23, S. 111]). Häufig verwendet wird das Metamodell *ArchiMate* [GAM24, S. 14]. Dieses kann toolübergreifend verwendet werden. Im Rahmen einer Umfrage der BOC GROUP gaben 80 % der befragten Unternehmen an, ein IT-Werkzeug für das EAM im Einsatz zu haben [GAM24, S. 16]. Als etabliertes nicht kostenpflichtiges Tool kann *ArchiMate* im Tool *Archi* zur Modellierung verwendet werden [BS24-ol]. Oftmals fehlt es den domänenspezifischen Sprachkonstrukten aber an Interoperabilität und einer Architekturvision zwischen den verschiedenen Perspektiven (z. B. Architektur und Geschäftsperspektive voneinander getrennt in UML und BPMN) [Lan17, S. 37].

Der Hauptnutzen eines effizienten EAM ist eine transparente und effiziente Planung und Steuerung hin zur operativen und strategischen Exzellenz von IT und Geschäft [Han13, S. 154]. EAM nutzt dafür als zentrales Managementobjekt unter anderem das abstrakte Element der Capability. Eine **Capability** (Deutsch: *Fähigkeit*) beschreibt, „Was?“ ein Unternehmen leisten kann. Der Fokus liegt nicht auf dem „Wie?“ (z. B. IT-System zur Ausführung) oder „Wer?“ (z. B. der Verantwortliche) [Lan17, S. 86]. Capabilities verbinden die Elemente der Unternehmensarchitektur (Systeme, statisch) mit dem Geschäft (Prozesse, dynamisch) und der dazu übergeordneten Strategie [BIT11, S. 13]. Sie werden in Capability Maps<sup>9</sup> („Fähigkeitskarten“) aggregiert visualisiert. Dies dient der Übersichtlichkeit [Lan17, S. 86]. Typischerweise werden Capabilities zwei bis drei Ebenen tief [Lan17, S. 210] und nach ihrer Art gruppiert (z. B. IT-Capability, Core-Capability, Business-Capability) [Wiß18, S. 97].

**Bedeutung im Kontext der Ausarbeitung:** EAM ist primär für das Business-IT-Alignment konzipiert worden. Jedoch bringt es eine Menge an relevanten Techniken, Werkzeugen und Prinzipien mit sich, die es zur Konzeption von Analytics Use Cases im Folgenden zu analysieren gilt. Insbesondere der interdisziplinäre Charakter und die Integration von Lösungen in existierende IT-Systeme ist eine geteilte Herausforderung zwischen der Analytics Konzeption und dem EAM.

### 2.5.5 Konzeption von Analytics Use Cases

EAM dient übergreifend als Mediator zwischen verschiedenen kollidierenden, nicht harmonisierten Architekturdomänen (Informationsdomäne, Prozessdomäne, Applikationsdomäne, Technik, Produkt) [Lan17, S. 44]. Dazu bildet die **Konzeption von Analytics**

---

<sup>9</sup> Je nach herangezogenem Standardwerk gibt es im EAM verschiedene sogenannte Content Frameworks (vgl. z. B. [IEC42010, S. 16, Togaf10]). Diese geben Beispiele für mögliche Perspektiven und strukturierende Artefakte zum Management der Unternehmensarchitektur. Diese Frameworks haben in der Regel einen hohen Abstraktionsgrad und sind nicht ohne Weiteres in der Praxis anzuwenden [Han13, S. 192].

**Use Cases** die Grundlage zur späteren Entwicklung von Analytics Lösungen. Für Analytics Use Cases in der Produktion überlagern sich Herausforderungen aus verschiedenen Domänen. Diese müssen alle gleichsam berücksichtigt werden. Neben der Strategie und dem Management (vgl. [WMK+24]) müssen die Besonderheiten der Industrial Data Science berücksichtigt werden [ENM+20].

Bei der Entwicklung von Analytics Use Cases wird in der Regel in die Unternehmensarchitektur eingegriffen [EWB+24]. Zur Umsetzung von Analytics Use Cases nehmen die Synchronisation und das Management der dahinterliegenden IT-Architektur eine immer größere Rolle bei komplexeren Lösungen ein [EWB+24]. Für die Skalierung von KI und Analytics Use Cases werden demnach robuste Rahmenwerke zur Steuerung dieses Eingriffs benötigt [SvS+24, S. 180]. Für Analytics Use Cases gibt es im Speziellen kein etabliertes Rahmenwerk, welches relevante Betrachtungsstandpunkte standardisiert definiert. Ansätze wie das „Industrial AI Framework“ schlagen vor, eine geschäfts-, nutzungs-, funktional- sowie implementierungszentrierte Perspektive einzunehmen [DFK+22, S. 7].

Je nach **Perspektive** des Betrachters kann ein System aus verschiedenen Architekturdomänen betrachtet werden [Lan17, S. 44]. Dabei sind diese Perspektiven in der Regel nicht unabhängig voneinander und weisen eine starke Relation auf [Lan17, S. 123]. Dennoch kann eine gezielte Auswahl von Perspektiven die Komplexität bei der Konzeption verringern und die einzelnen Architekturen teilweise voneinander entkoppeln [BIT11, S. 12]. Im Rahmen der Ausarbeitung wird auf das Modell von BITKOM zurückgegriffen [BIT11]. Es folgt eine Auflistung möglicher Betrachtungsstandpunkte in Bild 2-10 [BIT11, S. 13].

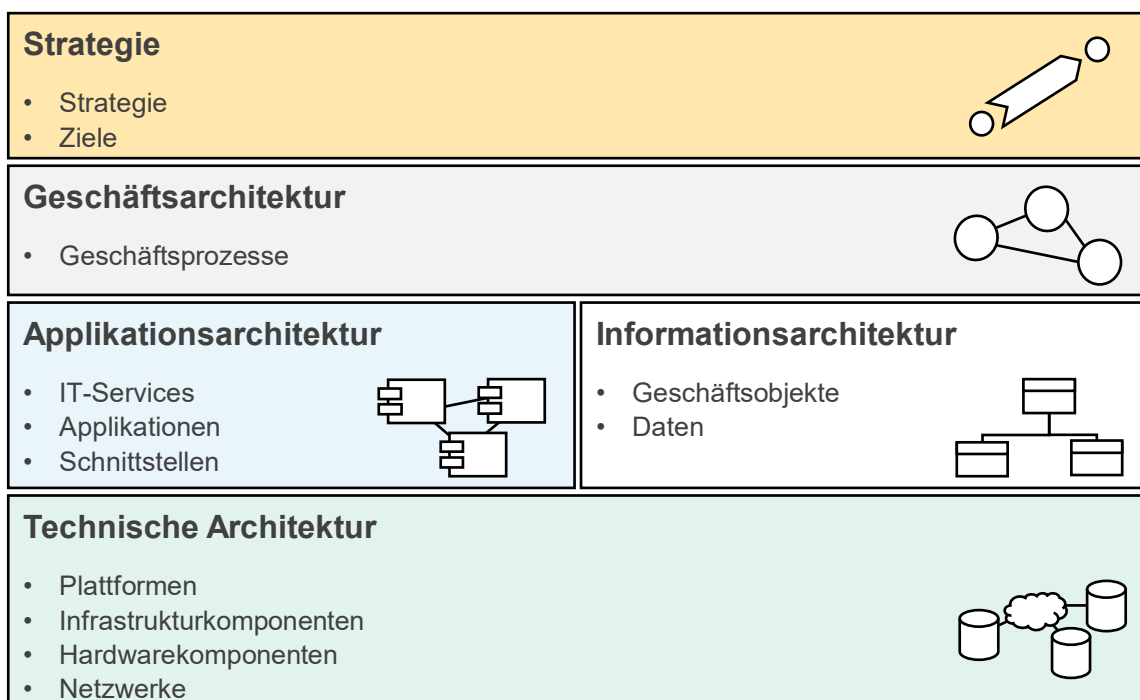


Bild 2-10: EAM-Ebenen einer Unternehmensarchitektur nach BITKOM [BIT11, S. 13]

- **Strategie:** Die Perspektive der Strategie aggregiert relevante Strategien und Ziele [BIT11, S. 13]. Die Skalierung von Analytics und KI Use Cases muss auf strategische Ziele einzahlen [SvS+24, S. 180], daher sollte diese Perspektive auch bei technischen Sachverhalten nicht vernachlässigt werden.
- **Geschäftsarchitektur (Prozess):** Bei der Betrachtung von Analytics Use Cases aus Prozesssicht steht deren Verankerung im Vordergrund. Ergänzend dazu kann auch der Ablauf in der Interaktion mit der Lösung im Use Case selber der Betrachtungsgegenstand sein. [JEK+19, KTK+23, SKK+23]
- **Applikationsarchitektur und Informationsarchitektur (Daten):** Diese beiden Architekturen beschreiben die IT-Bebauung sowie die damit verbundenen Datenmodelle und -objekte [BIT11, S. 13]. Die Applikationsarchitekturen können sich auf das gesamte Unternehmen oder einzelne Applikationen beziehen (z. B. nur den Use Case [WST+20]). Auf dieselbe Art können Datenmodelle einen ganzheitlichen Anspruch haben (z. B. ein Datenkatalog [JO23]) oder sich nur auf einen Use Case beziehen [WMK+24].
- **Technische Architektur:** Die technische Architektur beschreibt Infrastrukturkomponenten (z. B. Plattformen oder Server), welche zum Betrieb der Analytics Lösungen benötigt werden [BIT11, S. 13]. Die technologische Architektur kann die ganze Fabrik (z. B. [RRW+22, S. 133]) oder nur die Verarbeitungskette (Pipeline) in einem Use Case (z. B. [PLN+21]) im Fokus haben.

**Bedeutung im Kontext der Ausarbeitung:** Die Konzeption von Prescriptive Analytics Use Cases bildet den zentralen Gegenstand der Ausarbeitung. Befähigt wird die Phase der Konzeption durch eine ausreichend genaue Planung und ein kontinuierliches Management verschiedener Konzeptionsvorhaben. Auch wenn die iterative Implementierung ein der Ausarbeitung nachgelagerter Prozess ist, impliziert dieser eine Grundmenge an Anforderungen an die vorhergehenden Phasen der Entwicklung (Planung, Konzeption und Integration).

### 2.5.6 Implementierung von Analytics Use Cases

Analytics Use Case Entwicklungsvorgehen sind in der Regel iterativ gestaltet [HMS+23]. Bei der iterativen **Implementierung von Analytics Lösungen** wird der Cross-Industry-Process-for-Data-Mining (CRISP-DM) als übergreifender Quasistandard genutzt [BSS23, S. 13]. CRISP-DM zeichnet sich als Standardprozess durch seine anwendungs- und branchenunabhängige Gestaltung aus [She00]. Das Arbeiten mit Standards und das Anleihen der internen Prozesse an einen Referenzprozess befähigt Unternehmen dazu im Bereich Analytics zu kollaborieren und einen übergreifenden Wissensaustausch anzustoßen [EWB+24]. Der Prozess ist kohärent und gut dokumentiert [PF17, S. 52].

Es gibt diverse Abwandlungen und Instanziierungen des CRISP-DM für produzierende Unternehmen. Prominent verwendet wird der KDD Prozess (Knowledge Discovery in Databases) [Fay96] und die VDI/VDE-Richtlinie 3714 [VDI/VDE 3714 Blatt 1]. Die

DMME (data mining methodology for engineering applications) erweitert den Prozess um Aspekte der physischen Welt und fügt Schritte der „technischen Umsetzung“ hinzu [HWS+19, S. 406]. Eine Erweiterung von *MERKELBACH ET AL.* fokussiert sich auf die Ergänzung von Komponenten zur Integration von Citizen Data Scientists (siehe Kapitel 2.3.4) [MEK+22]. *NOLTE ET AL.* erweitern das Vorgehensmodell um Aspekte von Change- und Projektmanagement entlang des Vorgehens [NSM+20]. Alle Prozesse behandeln größtenteils dieselben Phasen mit teilweise abweichender Nomenklatur [BK21, S. 153, KM06, S. 8]. Eine Analyse weiterer Vorgehensmodelle ist in Anhang A3.1 beigefügt. In stellvertretender Repräsentation für viele der iterativ geprägten Data Science Entwicklungsvorgehen wird der **CRISP-DM** genauer erläutert (vgl. Bild 2-11).

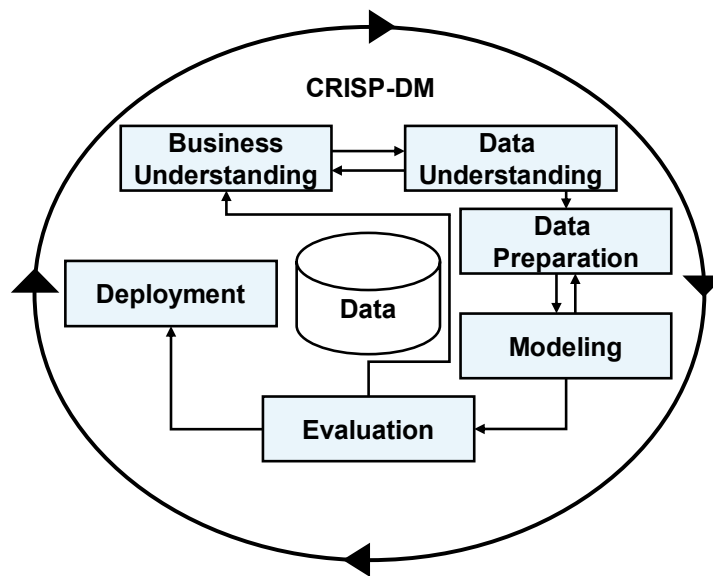


Bild 2-11: CRISP-DM Prozess nach SHEARER [She00, S. 14]

Der CRISP-DM verläuft nicht linear und wird mehrmals durchlaufen. Im Mittelpunkt stehen die zur Verfügung stehenden Daten [She00]. Die Phase des **Business Understanding** bildet das generelle Generieren eines aufgabenspezifischen Verständnisses ab. Mithilfe des Datenverständnisses (**Data Understanding**) wird der Lösungsraum aufgespannt und die Aufgabenstellung basierend auf Kosten und Nutzen der möglicherweise zu berücksichtigenden Daten definiert [PF17, S. 52]. Bei der Datenaufbereitung (**Data Preparation**) werden die Daten in der benötigten Qualität für die Modellierung im benötigten Format zusammengeführt. Dieser Schritt nimmt oftmals das größte Zeitkontingent in Anspruch und definiert die Erfolgsaussichten des angestrebten Data Analytics Vorhabens [HOS20, S. 14]. Mithilfe des Ergebnisses der Modellierung (**Modeling**) wird der Schritt neu angestoßen, bis das Modell in der geforderten Güte vorliegt. Das Modell wird evaluiert (**Evaluation**) und je nach Ergebnis entweder im Feld ausgerollt (**Deployment**) oder die Aufgabenformulierung noch einmal angepasst und der Zyklus von vorn begonnen. Der umschließende Ring in Bild 2-11 hebt hervor, dass zwischen den Phasen auch gesprungen werden kann und der Mehrwert nur durch Iteration generiert wird [PF17,

S. 52, She00]. Ergänzend dazu müssen bei Analytics Use Case Entwicklungen Methoden des Projektmanagements berücksichtigt werden [HBK+24].

**Bedeutung im Kontext der Ausarbeitung:** Der Implementierung der Analytics Use Cases müssen passgenau Informationen (z. B. Business Understanding, Data Understanding und Deployment) zur Verfügung gestellt werden. Für Prescriptive Analytics Use Cases ist insbesondere die Phase des Business und Data Understanding aufgrund der inhärenten Komplexität der Use Cases entscheidend. Ein weitreichender Eingriff in die vorher existierende Unternehmensarchitektur wird nötig.

## 2.6 Problemabgrenzung

Fabriken befinden sich im Wandel hin zu vernetzten und adaptiven Produktionssystemen [Aca24], wobei die zunehmende Anwendung von Data Analytics in der Produktion ein Schlüsselfaktor ist [RRH+24, S. 438]. Prescriptive Analytics unterstützt in diesem Wandel bei der Umsetzung der Reifegradstufen Vorausschau und Adaption für die Vision der Industrie 4.0 (siehe Kapitel 2.2.2).

Das Technologiefeld Prescriptive Analytics wird im jährlichen Hype Cycle von GARTNER des Jahres 2022 so eingeschätzt, dass während der Entstehung der Ausarbeitung das volle Potential erreicht wird [Gar22b]. Weiterhin listen Firmen wie BMW in ihrem Trendradar die Technik bereits als eine der Top-Drei Technologien auf die direkt reagiert werden sollte [BMW22]. Trotzdem sind Prescriptive Analytics Use Cases bisher wenig verbreitet (siehe Kapitel 2.4.1). In der Produktion und im Maschinenbau bleibt es oft bei einzelnen Pilotprojekten und Insellösungen [GBW22, WB23]. Der echte Mehrwert von Prescriptive Analytics in der Produktion entsteht erst durch die Erreichung von höheren Automatisierungsgraden und der Vernetzung dieser Insellösungen (siehe Kapitel 2.4.2). Ohne Automatisierung stellen konventionelle Analytics Use Cases lediglich verbesserte Entscheidungsgrundlagen zur Verfügung. Ein weiterer Aspekt ist die Transformation nicht präskriptiver in Prescriptive Analytics Use Cases, wobei bisherige Ansätze diesen Schritt nicht adressieren.

Einer der Hauptgründe für die mangelhafte Durchdringung in der Praxis ist die **fehlende Unterstützung der ganzheitlichen Entwicklung** von Prescriptive Analytics Use Cases. Dies begründet sich unter anderem durch den Umstand, dass es kein einheitliches oder ganzheitliches Vorgehensmodell für die Planung, Konzeption und Integration von Analytics Use Cases gibt. Die Konzeption von Prescriptive Analytics Use Cases erfordert ein effektives Management der Komplexität (siehe Kapitel 2.5.5). Im Bereich der Integration von Prescriptive Analytics Use Cases in die Produktion besteht eine hohe Interkonnektivität zu anderen Forschungsfeldern wie dem EAM (siehe Kapitel 2.5.1). Prescriptive Analytics Use Cases sind komplex in ihrer Umsetzung und müssen nahtlos in die existierende IT-Architektur der Produktion eingefasst werden. Um komplexe Prescriptive Analytics Use Cases zu realisieren, ist die Konzeption von großer Bedeutung.

Aus **Forschungsperspektive** ist Prescriptive Analytics in der Produktion ein junges Forschungsfeld, das durch aktuelle Entwicklungen wie der generativen KI vorangetrieben wird [NMW+25, Tho23, S. 912]. Dies bietet die Chance, durch Strukturierung, Systematisierung und Unterstützung bei der Erhöhung der technologischen Reife einen Mehrwert zu schaffen. In der **Praxis** realisieren Unternehmen zunehmend, wie wichtig ein reflektierter Umgang mit Daten und KI-Systemen für ihre Rationalisierungsbestrebungen sind [HHS24, S. 10]. Trotzdem liegt eine hohe Abhängigkeit von externen Unterstützern (Beratungen oder Dienstleistern) vor [HHS24, S. 13]. Die Integration von Prescriptive Analytics kann helfen, die Lücke zwischen theoretischen Ansätzen der Entscheidungsfindung und praktischen Anwendungen zu schließen. Aus der Problematik ergeben sich drei zu adressierende Handlungsfelder (vgl. Bild 2-12).

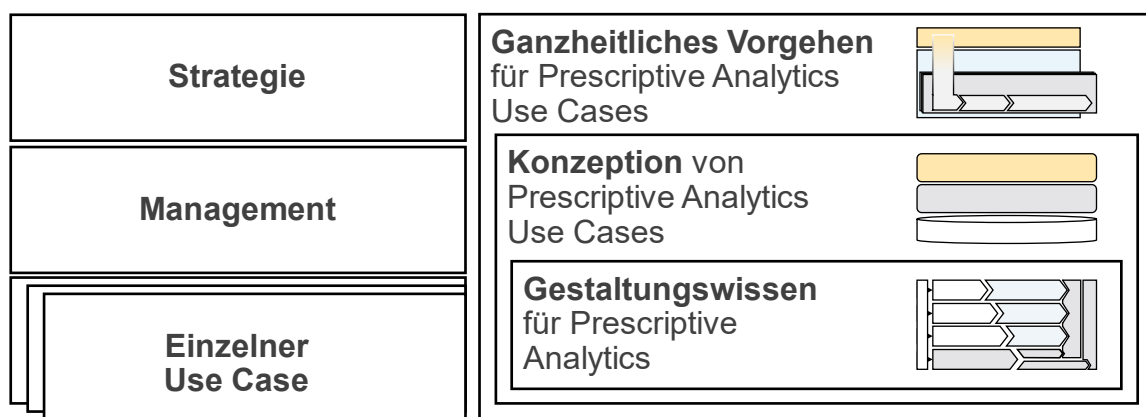


Bild 2-12: Handlungsfelder der Spezifikationstechnik

Neben einem **ganzheitlichen Vorgehen** für Prescriptive Analytics Use Cases und der **Konzeption** von Prescriptive Analytics Use Cases wird mögliches **Gestaltungswissen** für Prescriptive Analytics Use Cases betrachtet. Diese Handlungsfelder werden im Folgenden jeweils kurz erläutert. Die Handlungsfelder zum Vorgehen und zur Konzeption beschreiben die Unterstützung der Use Case Entwicklung (Problemraum). Das Handlungsfeld der Gestaltung fokussiert sich auf die Möglichkeiten zur Umsetzung (Lösungsraum).

### Handlungsfeld 1: Ganzheitliches Vorgehen für Prescriptive Analytics Use Cases

Die Komplexität von Prescriptive Analytics Use Cases zeigt sich bei der Planung und Einführung in die Produktion (siehe Kapitel 2.5.3) insbesondere durch fehlende standardisierte Prozesse bei der Entwicklung und unklare Schritte bei der Integration. Zudem müssen Probleme in der interdisziplinären Zusammenarbeit (siehe Kapitel 2.3.4) zwischen Data Science, Produktion und IT adressiert werden. Eine strategische Herangehensweise ist essenziell, da Prescriptive Analytics Use Cases übergreifende Auswirkungen

auf die Produktion haben (siehe Kapitel 2.4.1). Ohne ein festes Vorgehensmodell entstehen Unsicherheiten und ineffiziente Abläufe bei der Einführung von Prescriptive Analytics Use Cases in die Produktion (siehe Kapitel 2.5.3).

Weiterhin sollten Analytics Use Cases generell mit den Unternehmensinteressen im Einklang ausgewählt sein. Dies kann durch ein übergeordnetes Vorgehen sichergestellt werden (siehe Kapitel 2.5.1). Dieses muss die Ebenen der Strategie, des Managements mehrerer Use Cases sowie die Entwicklung einzelner Use Cases berücksichtigen.

## **Handlungsfeld 2: Konzeption von Prescriptive Analytics Use Cases**

Prescriptive Analytics Use Cases werden mit anderen Analytics Use Cases in der Produktion vernetzt, um Synergiepotenziale auszunutzen und die Entscheidungsfindung zu verbessern (siehe Kapitel 2.4.2). Dies hat zur Folge, dass ein größerer Planungshorizont mit ganzheitlicheren Auswirkungen auf die existierende Produktion betrachtet werden muss (siehe Kapitel 2.4.1). Dies wirkt sich auch auf die zu betrachtenden Architekturebenen aus. Ein weitreichender Eingriff in die Unternehmensarchitektur wird erforderlich (siehe Kapitel 2.5.5). Eine Modularisierung der Umsetzungskomponenten muss berücksichtigt werden. Zudem bestehen Schwierigkeiten, die Voraussetzungen für Prescriptive Analytics Use Cases präzise abzubilden und zu bewerten. Dies beinhaltet die Berücksichtigung aller relevanten Perspektiven aus Data Science, Produktion und IT (siehe Kapitel 2.5.4).

Es mangelt an Struktur bei der Spezifikation von Use Cases, weshalb ein durchdachtes Konzept den notwendigen Überblick gewährleisten muss. Ein Modellierungskonzept mit Partialmodellen kann helfen diese Komplexität zu bewältigen.

## **Handlungsfeld 3: Gestaltungswissen für Prescriptive Analytics**

Die Umsetzung einzelner Prescriptive Analytics Use Cases erfordert die Erweiterung des zu berücksichtigenden Datenraums um den Aktions- und Handlungsraum (siehe Kapitel 2.1.3). Dies erhöht die Komplexität der Umsetzung direkt. Es besteht ein Bedarf an methodischer Unterstützung durch adäquate Artefakte, um den Arbeitsaufwand zu reduzieren und ein systematisches Vorgehen zu fördern.

Eine Verknüpfung mit einem Modellierungskonzept sollte den strukturierenden Rahmen stellen, insbesondere für bereits existierende und etablierte Ansätze zur Konzeption von allgemeinen Analytics Use Cases.

## **Resultierender Bedarf**

Basierend auf den beschriebenen Handlungsfeldern ergibt sich der Bedarf für eine *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion*. Die Spezifikationstechnik soll die Entwicklung von Prescriptive Analytics Lösungen in der Produktion

verbessern. Sie soll die Perspektiven der Planung, Konzeption und Integration der Lösungen durch die Unterstützung des Analytics Architekten verbessern<sup>10</sup>. Indirekt werden die nachfolgenden Phasen der Analytics Use Case Entwicklung unterstützt. Die Adressierung dieser Perspektiven erfordert einen holistischen und interdisziplinären Ansatz, der Aspekte aus dem Management der Produktion sowie der Entwicklung von Prescriptive Analytics Use Cases berücksichtigt. Dazu soll die Spezifikationstechnik die folgenden Bestandteile beinhalten:

- Ein **Strukturierungsrahmen** für Grundlagenwissen über Prescriptive Analytics Use Cases wird benötigt, um den Herausforderungen in der Use Case Entwicklung gerecht zu werden. Dieser Strukturierungsrahmen soll bei der Identifikation neuer Prescriptive Analytics Use Cases unterstützen.
- Ein **Vorgehensmodell** wird benötigt, um die Planung, Konzeption und Integration für Prescriptive Analytics Lösungen zu unterstützen. Dabei muss Komplexität gehandhabt und die Zusammenarbeit verschiedener Akteure sichergestellt werden. Insbesondere die fehlenden Schnittstellen zwischen Strategie, Programmmanagement und einzelner Use Case Entwicklung müssen ganzheitlich adressiert werden (siehe Kapitel 2.5.1)
- Die strukturierte Entwicklung einzelner Prescriptive Analytics Use Cases sowie deren Integration in eine existierende Unternehmensarchitektur benötigt ein **Modellierungskonzept**. Verschiedene Perspektiven müssen berücksichtigt werden (z. B. Data Scientist und Nutzer, siehe Kapitel 2.3.4).
- Zur Steigerung der Effektivität und Effizienz bei der Entwicklung von Prescriptive Analytics Use Cases werden **Artefakte zur Unterstützung** benötigt. Dieses wird in strukturierter Form für eine mehrfache Verwendung bereitgestellt. Insbesondere die Erzeugung von wiederverwendbaren Elementen in der Entwicklung neuer Use Cases sowie deren Integration in eine Unternehmensarchitektur und -organisation sind besonders herausfordernd (siehe Kapitel 2.5.5).
- Die Herausforderung in der Praxis liegt darin, dass die verschiedenen Perspektiven auf einen Prescriptive Analytics Use Case auch in verschiedenen Werkzeugen verwaltet werden. Um die Praxistauglichkeit zu gewährleisten, wird eine **Werkzeugunterstützung** benötigt. Diese kann die einzelnen Konzepte in der Praxis operationalisieren, indem die Nutzbarkeit durch ein Werkzeug erhöht wird. Tiefgreifende Analysen der eigentlichen Entwicklung werden so erst ermöglicht.

---

<sup>10</sup> In der Design Science Research gibt es keine eigentliche Forschungsthese. Vielmehr wird Unterstützungsbedarf identifiziert und durch an praktischen Bedarfen orientierte Artefakte unterstützt. Anstatt einer These wird auf Anforderungen zurückgegriffen, welche zur Messung der Zielerreichung dienen.

## 2.7 Anforderungen an die Spezifikationstechnik

Um der geforderten Strenge (Rigor) an die wissenschaftliche Ausarbeitung gerecht zu werden (siehe Kapitel 1.4), sollten die **Anforderungen an die Spezifikationstechnik** auf einschlägiger Literatur beruhen und auf den angegebenen Herausforderungen in der Problematik aufbauen. Basierend auf den drei hergeleiteten Handlungsfeldern (übergeordnetes Vorgehen, Konzeption, Gestaltungswissen) werden acht Anforderungen an die *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* abgeleitet. Die nach den Handlungsfeldern strukturierten Anforderungen werden im Folgenden beschrieben. Ein Überblick sowie die Zuordnung zu den Handlungsfeldern sind Bild 2-13 zu entnehmen. Die Anforderungen sind als Zielstellungen zu verstehen. Anhand ihrer kann die Eignung einzelner Ansätze zur Problemlösung beurteilt werden.

<b>Ganzheitliche Vorgehen</b> für Prescriptive Analytics Use Cases	<b>A1</b>	Anwendbar für produzierende Unternehmen
	<b>A2</b>	Unterstützung beim Management der Synergien zwischen Use Cases
	<b>A3</b>	Unterstützung beim Vorgehen der Konzeption von Prescriptive Analytics Use Cases
<b>Konzeption</b> von Prescriptive Analytics Use Cases	<b>A4</b>	Berücksichtigung unterschiedlicher Perspektiven für Prescriptive Analytics
	<b>A5</b>	Definition von Schnittstellen mit der bestehenden Unternehmensarchitektur
	<b>A6</b>	Berücksichtigung der Integration zukünftiger Technologien
<b>Gestaltungswissen</b> für Prescriptive Analytics	<b>A7</b>	Unterstützung bei der Umsetzung neuer Prescriptive Analytics Use Cases
	<b>A8</b>	Analysierbare Zusammenhänge von Entscheidungen

Bild 2-13: Überblick über die Anforderungen sortiert nach den Handlungsfeldern

### Handlungsfeld 1: Ganzheitliches Vorgehen für Prescriptive Analytics Use Cases

Die Überschneidung von Planung, Konzeption und Integration einzelner Prescriptive Analytics Use Cases ist eine Herausforderung, die alle Arten von Analytics betrifft. Daraus werden Anforderungen an das Design der Spezifikationstechnik innerhalb des Handlungsfeldes abgeleitet (siehe Kapitel 2.5):

#### Anforderung 1: Anwendbar für produzierende Unternehmen

Um das richtige Maß an Granularität in dem gegebenen Konzept zu finden, wird ein Konzept angestrebt, das auf den Bereich der Produktion anwendbar ist (siehe Kapitel 2.2). Die meisten bestehenden Ansätze konzentrieren sich auf eine bestimmte Domäne wie Wartung oder Produktionsplanung mit einem engen Use Case Fokus.

### **Anforderung 2: Unterstützung beim Management der Synergien zwischen Use Cases**

Zur Sicherstellung eines vorteilhaften Aufwand-Nutzen-Verhältnisses bei der Auswahl von Prescriptive Analytics Use Cases muss diese methodisch unterstützt und die Zusammenhänge zwischen den einzelnen Use Cases in der Konzeption gemanagt werden (siehe Kapitel 2.5.2). Dies bedeutet, Prescriptive Analytics Use Cases im gegebenen System der Produktion nicht getrennt zu analysieren, sondern mögliche Schnittstellen und Synergien zu berücksichtigen. Hier sind Schnittstellen bei der Findung möglicher Use Cases für den Betrachtungsraum gemeint.

### **Anforderung 3: Unterstützung beim Vorgehen der Konzeption von Prescriptive Analytics Use Cases**

Ein strukturierter Ansatz zur Konzeption von Prescriptive Analytics Use Cases ist erforderlich, um die Integration und das Zusammenspiel der verschiedenen Use Cases im Unternehmenskontext zu gewährleisten (siehe Kapitel 2.5.5). Dazu muss der Prozess auf der strategischen, taktischen und operativen Ebene von der Idee bis hin zum umgesetzten Prescriptive Analytics Use Case berücksichtigt werden.

### **Handlungsfeld 2: Konzeption von Prescriptive Analytics Use Cases**

Übergeordnet gilt es nicht nur die richtigen Use Cases auszuwählen, essenziell wichtig ist auch deren Integration in den existierenden Unternehmenskontext (existierende IT-Systeme, Organisation, Management und Strategie). Diese ist entsprechend durch geeignete Artefakte zu unterstützen.

### **Anforderung 4: Berücksichtigung unterschiedlicher Perspektiven für Prescriptive Analytics**

Für die Anwendung des Konzepts ist die Berücksichtigung verschiedener Architekturperspektiven essenziell, um eine industriennahe Anwendung zu gewährleisten (siehe Kapitel 2.5.1). Neben der Prozess-, Applikations-, Daten- und technischen Architektur muss auch die strategische Architektur berücksichtigt werden. Die Entwicklung von Use Cases muss über alle Phasen hinweg mit geeigneten Perspektiven für den Anwender unterstützt werden. Dazu zählen die Planung, Konzeption und Integration der Prescriptive Analytics Use Cases. Diese speisen sich aus den Domänen des Produktionsmanagements, der IDS und dem EAM.

### **Anforderung 5: Definition von Schnittstellen mit der bestehenden Unternehmensarchitektur**

Es ist es essenziell, die weitere Schaffung von Insellösungen bei neuen Prescriptive Analytics Use Case Entwicklungen zu verhindern (siehe Kapitel 2.3.2). Dafür müssen Schnittstellen der Use Cases mit der Umgebung festgelegt werden. Weiterhin benötigen

Prescriptive Analytics Use Cases eine Vielzahl an Kontextinformationen und sind daher auf Daten aus anderen Quellen angewiesen (siehe Kapitel 2.4.3).

### **Anforderung 6: Berücksichtigung der Integration zukünftiger Technologien**

Ein zentrales Element, welches Prescriptive Analytics Use Cases von anderen Analytics Use Cases unterscheidet, ist der starke Fokus auf eine zu treffende Entscheidung [WZ23, S. 2]. Dementsprechend muss bei der Konzeption der Use Cases die Entscheidung in den Mittelpunkt gestellt und im Prozess berücksichtigt werden (siehe Kapitel 2.4.1). Ein möglichst hoher Grad an Lösungsneutralität ist aufgrund der rasanten Entwicklung im Bereich der Data Science unabdingbar. Prominente Beispiele sind die Entwicklung von Prescriptive Analytics als Technologiefeld (siehe *GARTNER* Hype Cycle [Gar22b]), der Befähiger-Technologien wie generativer KI [DD23] und der Trend hin zu Analytics-as-a-Service Lösungen [LPR+23, S. 13] (siehe Kapitel 2.4.2).

### **Handlungsfeld 3: Gestaltungswissen für Prescriptive Analytics**

Zur adäquaten Unterstützung bei der Konzeption von Prescriptive Analytics Lösungen gilt es zusätzlich die Menge an existierender Grundlagenforschung (Algorithmen, Umsetzungsmuster) entsprechend strukturiert den Anwendern zur Verfügung zu stellen. Dies soll einen Beitrag zur Überbrückung zwischen den existierenden Algorithmen und der fehlenden Verbreitung in der Praxis leisten (siehe Kapitel 2.1.3).

### **Anforderung 7: Unterstützung bei der Umsetzung neuer Prescriptive Analytics Use Cases**

Die Umsetzungsmöglichkeiten bei der Konzeption von Prescriptive Analytics Use Cases spielen aufgrund ihrer Implikationen für die spätere Entwicklung eine große Rolle. Dementsprechend früh müssen mögliche Implikationen der Umsetzungsformen eruiert werden und darauf basierend Leitentscheidungen für die weitere Entwicklung getroffen werden. Es gilt diese Unterstützung im Entwicklungsprozess strukturiert zur Verfügung zu stellen (siehe Kapitel 2.4.2).

### **Anforderung 8: Analysierbare Zusammenhänge von Entscheidungen**

Prescriptive Analytics Use Cases können schwer einzeln betrachtet werden und sind oft eingebettet in einen komplexen Entscheidungszusammenhang (siehe Kapitel 2.1.3). Daraus ergibt sich die Anforderung mögliche Zusammenhänge zwischen einzelnen Entscheidungen und den damit verbundenen Lösungen zu betrachten und in die Planung, Konzeption und Integration einfließen zu lassen. Beispiele hierfür sind gleiche genutzte Datenobjekte oder Input-Output Beziehungen in den Use Cases. Letztere können Konzepte verschiedener Use Cases voneinander abhängig machen.



### 3 Stand der Technik

Die vorhergehende Problemanalyse hat einen Bedarf für eine *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* aufgezeigt. Im Folgenden wird der Bedarf mit dem **Stand der Technik**<sup>11</sup> verglichen. Dafür werden die relevantesten Ansätze präsentiert und deren Eignung für die vorliegenden Anforderungen systematisch bewertet. Je Ansatz werden der Kerninhalt, der Hauptwertbeitrag, die Hauptunzulänglichkeiten sowie die daraus folgenden Implikationen für die Problemlösung abgeleitet.

Die Struktur des Kapitels orientiert sich an den **Handlungsfeldern** der Problemanalyse. **Kapitel 3.1** fasst Ansätze in Form ganzheitlicher Vorgehensmodelle für die Entwicklung von Analytics Use Cases zusammen. **Kapitel 3.2** dient dem Überblick über verschiedene Ansätze zur Unterstützung der Konzeption von Analytics Use Cases in der Produktion. In **Kapitel 3.3** werden Ansätze zur Strukturierung von Prescriptive Analytics Gestaltungswissen beleuchtet. Abschließend werden alle Ansätze zusammengefasst bewertet und eine Forschungslücke identifiziert.

#### 3.1 Vorgehensmodelle zur Entwicklung von Prescriptive Analytics Use Cases

Die im Folgenden beschriebenen Ansätze lassen sich alle im **Handlungsfeld** „Ganzheitliche Vorgehen für Prescriptive Analytics Use Cases“ verorten. Dieses Handlungsfeld fasst Ansätze zusammen, die übergeordnete **Vorgehensmodelle zur Prescriptive Analytics Use Case Entwicklung** im Kontext der Industrie 4.0 fokussieren. Die Reihenfolge der Ansätze orientiert sich an der Verwendung bei der Entwicklung von Prescriptive Analytics Use Cases. Bild 3-1 zeigt die Einordnung der Ansätze des ersten Handlungsfeldes basierend auf den im Unternehmen adressierten Ebenen (siehe Kapitel 2.5.1) und dem Konkretisierungsgrad der Lösung.

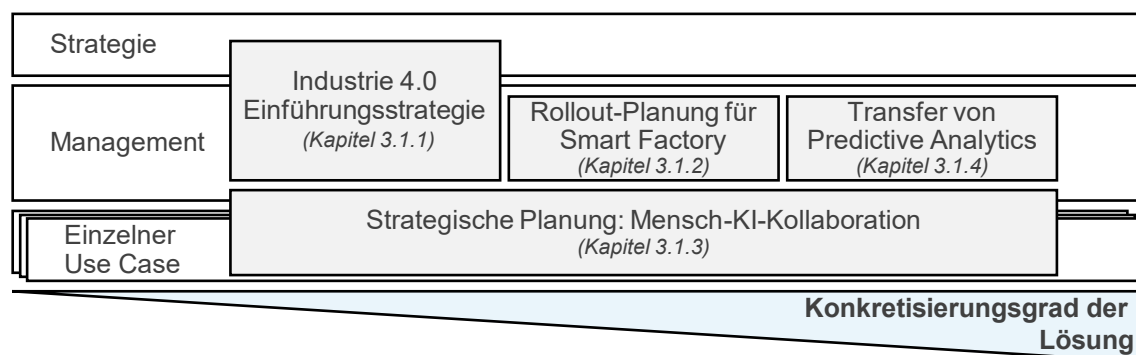


Bild 3-1: Einordnung der Ansätze nach der im Unternehmen adressierten Ebene aufbauend auf Kapitel 2.5.1 (eingeordnete Ansätze: [Mer16, BHF+23, ENM+20, GKD23])

<sup>11</sup> Grundlage des Stands der Technik stellen u.a. die strukturierten Literaturrecherchen aus folgenden Veröffentlichungen dar [WME+24, WMN+24, NMW+24, EWB+24, LWB+24].

Zuerst wird in **Kapitel 3.1.1** ein Ansatz zur Industrie 4.0 Einführung nach MERZ beschrieben. Darauf basierend wird in **Kapitel 3.1.2** ein Ansatz zur Rollout-Planung für Smart Factory Use Cases nach BUDDÉ ET AL. präsentiert. **Kapitel 3.1.3** und **Kapitel 3.1.4** widmen sich Ansätzen zur Implementierung und Planung von Analytics Use Cases (aus Predictive Analytics Perspektive nach VON ENZBERG ET AL. und Mensch-KI-Kollaborationsperspektive nach GABRIEL ET AL.).

### 3.1.1 Industrie 4.0 Einführungsstrategie nach MERZ

Im Folgenden wird der Ansatz zur Entwicklung einer **Industrie 4.0 Einführungsstrategie** nach MERZ vorgestellt [Mer16]. Zur Einführung von Industrie 4.0 bedarf es einer strukturierten Vorgehensweise [SAD+20]. Dies kann beispielsweise durch eine Einführungsstrategie (Top Down) vorgegeben werden. Neben der Ermittlung von strategischen Zielen (z. B. in Form eines Zielbildes) steht die Bewertung und Auswahl einer initialen Menge an Use Cases im Vordergrund. Diverse Autoren schlagen zur Bewertung von Industrie 4.0 Use Cases die Verwendung von Portfolios zur initialen Einschätzung von Aufwand und Nutzen vor [KML+19, ENM+20, JLT+19, Mer16]. Der **Hauptwertbeitrag** des Ansatzes nach MERZ ist ein portfoliobasiertes Vorgehensmodell zur Ermittlung einer Einführungsstrategie (vgl. Bild 3-2).

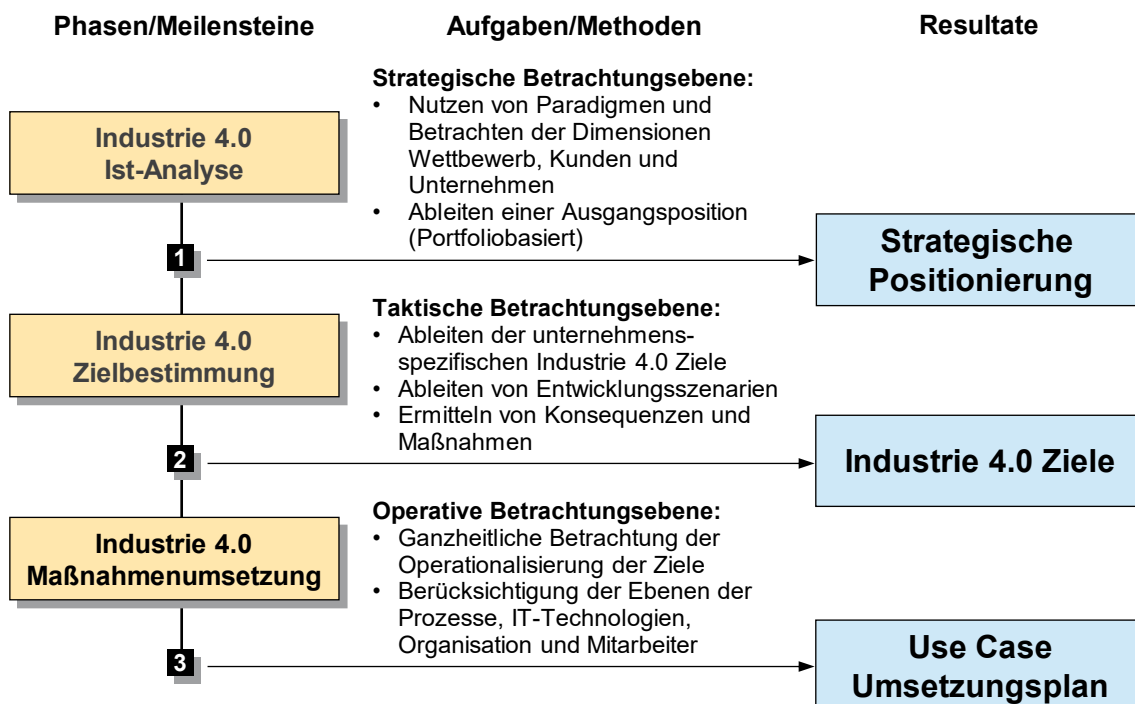


Bild 3-2: Entwicklung einer Industrie 4.0 Einführungsstrategie in Anlehnung an [Mer16, S. 96]

Phase eins fasst Aktivitäten mit dem Ziel der **strategischen Positionierung** zusammen. In der **Industrie 4.0 Ist-Analyse** wird dafür eine Betrachtung des Wettbewerbs des Unternehmens durchgeführt und die Ausgangsposition abgeleitet. Basierend auf der Standortbestimmung werden in Phase zwei die **Industrie 4.0 Ziele** durch eine **Industrie 4.0 Zielbestimmung** abgeleitet. Unternehmensspezifische Szenarien werden aufgestellt und daraus Maßnahmen abgeleitet. Die Phase drei (auf operativer Betrachtungsebene) fokussiert die **Industrie 4.0 Maßnahmenumsetzung** in den Dimensionen Prozesse, IT-Technologien, Organisation und Mitarbeiter. Daraus resultiert ein **Use Case Umsetzungsplan**. Der Hauptwertbeitrag liegt in der Ausdifferenzierung in die Ebenen, welche bei der Einführung synchronisiert werden müssen. Es ergibt sich ein generisches Vorgehen zur Einführung neuer Technologien oder Use Cases in Industrieunternehmen.

**Bewertung:** Die Industrie 4.0 Einführungsstrategie stellt einen geeigneten übergeordneten Rahmen für die strategische Verankerung einer Spezifikationstechnik dar. Die übergeordnete Struktur des Vorgehens sollte untersucht und wo sinnvoll integriert werden. Dazu zählen etablierte Managementinstrumente wie Portfoliotechniken. Herausfordernd bleibt für den Anwender die fehlende Konkretisierung im Vorgehen. Der managementzentrierte und Top Down agierende Ansatz berücksichtigt Aspekte wie mögliche Synergieeffekte zwischen den Use Cases innerhalb der Produktion nicht. Hierbei geht der Ansatz nach MERZ nicht spezifisch auf die Herausforderungen im Kontext (Prescriptive) Analytics ein. Der untersuchte Ansatz geht von einer kompletten Neueinführung der Industrie 4.0 in der Produktion aus.

### 3.1.2 Rollout-Planung für Smart Factory Use Cases nach BUDE ET AL.

Industrie 4.0 Use Cases sind in ihrem Einführungsaufwand schwer abzuschätzen (siehe Kapitel 2.2.1). Der **Ansatz zur Rollout-Planung für Smart Factory Use Cases** widmet sich dieser Herausforderung durch die Modularisierung der Use Case Einführung. Das Vorgehen nach BUDE ET AL. geht davon aus, dass bereits eine definierte Menge an Use Cases vorliegt [BHF+23]. Basierend darauf wird ein iteratives Vorgehen mit Zwischenschritten zur Implementierung von Best Practices und Controlling Schritten vorgestellt. Das Modell wird angereichert durch zu berücksichtigende Dimensionen, parallele Aktivitäten und Wirkzusammenhänge [BHF+23]. Der **Hauptwertbeitrag** der Veröffentlichung ist ein Vorgehensmodell mit definierten Schritten beim Roll-Out von Use Cases (vgl. Bild 3-3).

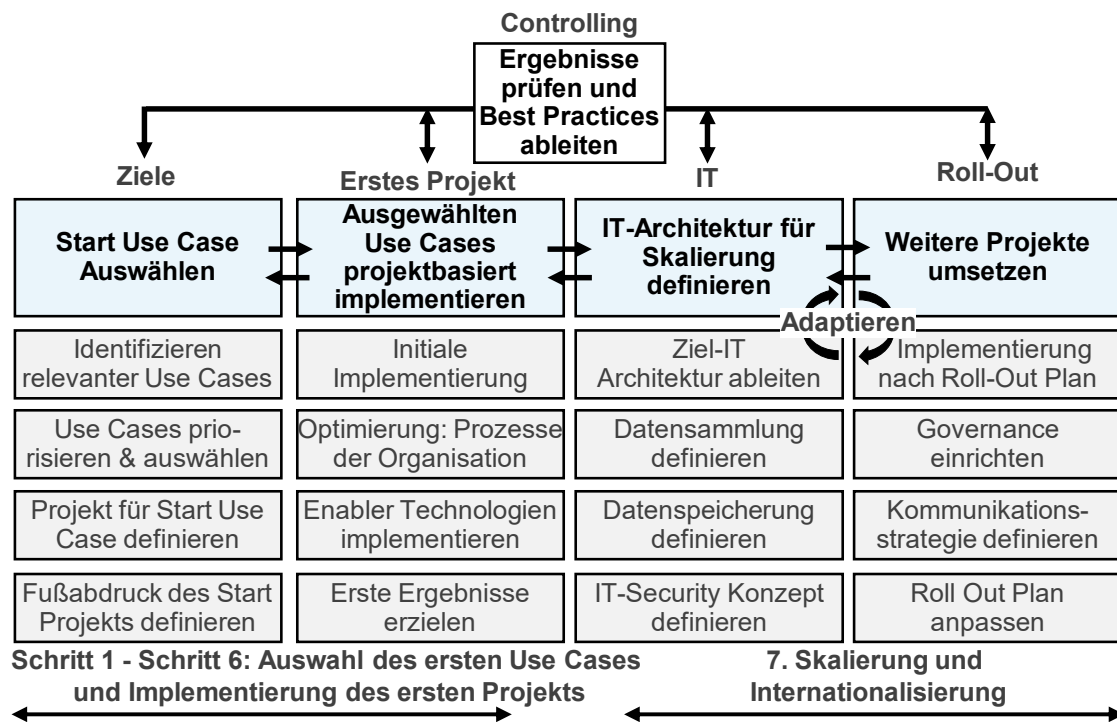


Bild 3-3: Modell für die Rollout-Planung von Smart Factory Use Cases nach BUDE ET AL. [BHF+23, S. 235]

Übergeordnet wird das iterative Vorgehen synchronisiert und **Best Practices** werden dokumentiert. Der Einstieg in das Vorgehen wird durch einen „**Start Use Case**“ gewählt. An der Implementierung dieses werden Erkenntnisse zur Skalierung abgeleitet. Diese Erkenntnisse enthalten Aspekte, wie der Use Case über die **IT-Architektur** für die ganze Organisation **skaliert** werden kann. Iterativ werden nachfolgend projektbasiert weitere Use Cases umgesetzt. Eine Beschreibung der Unteraktivitäten ist Bild 3-3 zu entnehmen. [BHF+23, S. 235]

Zusätzlich stellt der Beitrag einen Überblick zu Smart Factory Use Cases bereit. Die Übersicht adressiert nicht nur Analytics bezogene Use Cases. Neben der Fernwartung und dem Sustainability Tracking werden die Analytics Stufen (Descriptive Analytics bis Prescriptive Analytics) zur Strukturierung verwendet. Als (autonome) Prescriptive Analytics Use Cases werden die Nachfrageprognose, Bestandskontrolle, Produktionsplanung, Prozessoptimierung, Produktion, Montage, Instandhaltung und das Qualitätsmanagement genannt [BHF+23, S. 237].

**Bewertung:** Der Ansatz nach BUDE ET AL. gibt einen strukturierten Überblick über die Projektmanagementaktivitäten für das Roll-Out von Smart Factory Use Cases im Allgemeinen. Es liegt keine Ausrichtung auf Besonderheiten von Prescriptive Analytics Use Cases vor. Es wird keine einheitliche Definition zur Verfügung gestellt, was ein Use Case ist. Das Roll-Out Vorgehen setzt voraus, dass klar ist, welche Use Cases für das betrachtete System in Frage kommen.

### 3.1.3 Strategische Planung: Mensch-KI-Kollaboration nach GABRIEL ET AL.

Der Ansatz nach GABRIEL ET AL. verfolgt das Ziel, eine Grundgesamtheit an Use Cases strategisch zu planen, welche aus arbeitswissenschaftlicher Perspektive die **Mensch-KI-Kollaboration** in der Produktion fokussieren [GKD23]. Der Beitrag von GABRIEL ET AL. wurde auf der *CIRP CMS* veröffentlicht. Der Ansatz stellt einen Brückenschlag zwischen der strategischen Planung von Industrie 4.0 Use Cases und Use Cases mit einem Fokus auf der Mensch-KI-Kollaboration dar [GKD23]. Der **Hauptwertbeitrag** ist ein Vorgehensmodell zur strategischen Planung entlang der Ebenen der Strategie, des Programms und der einzelnen Use Case Projekte (vgl. Bild 3-4).

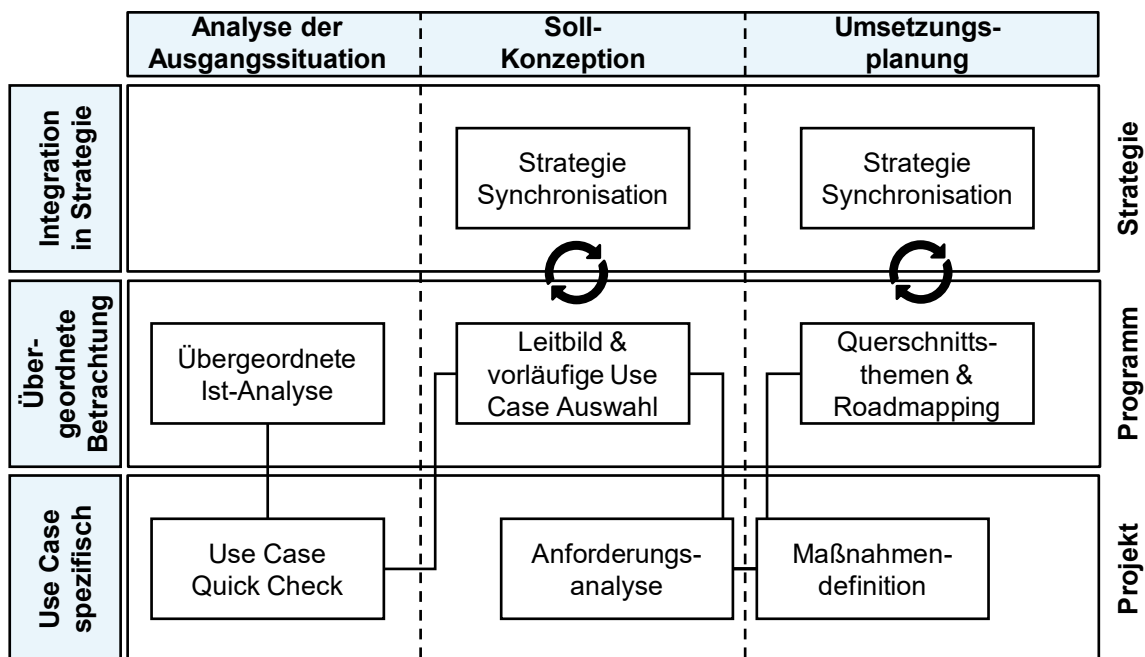


Bild 3-4: Vorgehensmodell für die strategische Planung der Mensch-KI-Kollaboration nach GABRIEL ET AL. [GKD23, S. 5]

Strategische **Programme** werden Top Down aus **Strategien** abgeleitet [GP14, S. 208] und können verschiedene Grundcharaktere annehmen. Generell bündeln sie eine Menge an Maßnahmen zu einem strategischen Ziel. Diese werden in **Projekten** umgesetzt [MSM+11, S. 4]. Zur Abbildung dieser Zusammenhänge wird in den Phasen der Analyse der **Ausgangssituation**, **Soll-Konzeption** und **Umsetzungsplanung** ein Vorgehen bereitgestellt. Zuerst wird eine **übergeordnete Ist-Analyse** durchgeführt. Basierend auf der Ist-Analyse wird ein **Use Case Quick Check** angestoßen. In diesem werden mögliche Use Cases eruiert. Das daraus abgeleitete **Leitbild** inklusive **vorläufig ausgewählter Use Cases** wird mit der dafür relevanten Strategie synchronisiert. Nach dem Abgleich mit der Strategie wird je Use Case eine **Anforderungsanalyse** durchgeführt. Aus diesen Analysen werden **Maßnahmen** abgeleitet. Final wird auf Programmebene eine **Roadmap** inklusive **Querschnittsthemen** abgeleitet. Mithilfe der Roadmap wird der Use Case im Rahmen der Umsetzungsplanung ein weiteres Mal mit der Strategie synchronisiert. [GKD23, S. 5]

**Bewertung:** Der Ansatz nach GABRIEL ET AL. zur strategischen Planung der Mensch-KI-Kollaboration stellt einen strukturierten Ansatz zur Use Case Planung bereit. Es liegt ein starker Fokus auf humanzentrierten Aspekten und eine Einschränkung auf KI-basierte Use Cases in der Methodik vor. Es wird bedarfsgerecht analysiert und die ermittelten Use Cases werden lediglich mit der Strategie synchronisiert und abgestimmt. Das Vorgehen endet mit definierten Use Cases. Das gesamte Vorgehen stellt nur eingeschränkte Hilfestellung für die Konzeption oder technische Umsetzung bereit. Jedoch bietet die Strukturierung nach Projekt, Programm und Strategie einen vielversprechenden Ansatz zum Management der Komplexität bei der Einführung mehrerer Use Cases in ein System.

### 3.1.4 Transfer von Predictive Analytics nach VON ENZBERG ET AL.

Der Beitrag beschreibt wie der **Transfer von Predictive Analytics** in die Produktion angegangen werden kann [ENM+20]. Der Beitrag nach VON ENZBERG ET AL. wurde im Journal *Frontiers in Computer Science* veröffentlicht. Ein Brückenschlag zwischen Herausforderungen in der Organisation und der Einführung von Analytics Use Cases wird hergestellt. Für das übergeordnete Vorgehen werden gängige Artefakte zur Unterstützung genutzt. Neben portfoliobasierten Ansätzen (siehe Kapitel 3.1.1) wird das betrachtete System mit Systems Engineering Ansätzen (insbesondere CONSENS, vgl. [GLL12, S. 89]) modelliert und die Nutzerinteraktion konzipiert [ENM+20, S. 4]. Die Artefakte und Perspektiven zur Konzeption werden lose genutzt und sind nicht strukturiert im Vorgehen verankert [ENM+20, S. 2]. Der **Hauptwertbeitrag** ist das Vorgehensmodell zur Einführung von Predictive Analytics Use Cases. Ein Überblick über das Vorgehensmodell ist Bild 3-5 zu entnehmen.

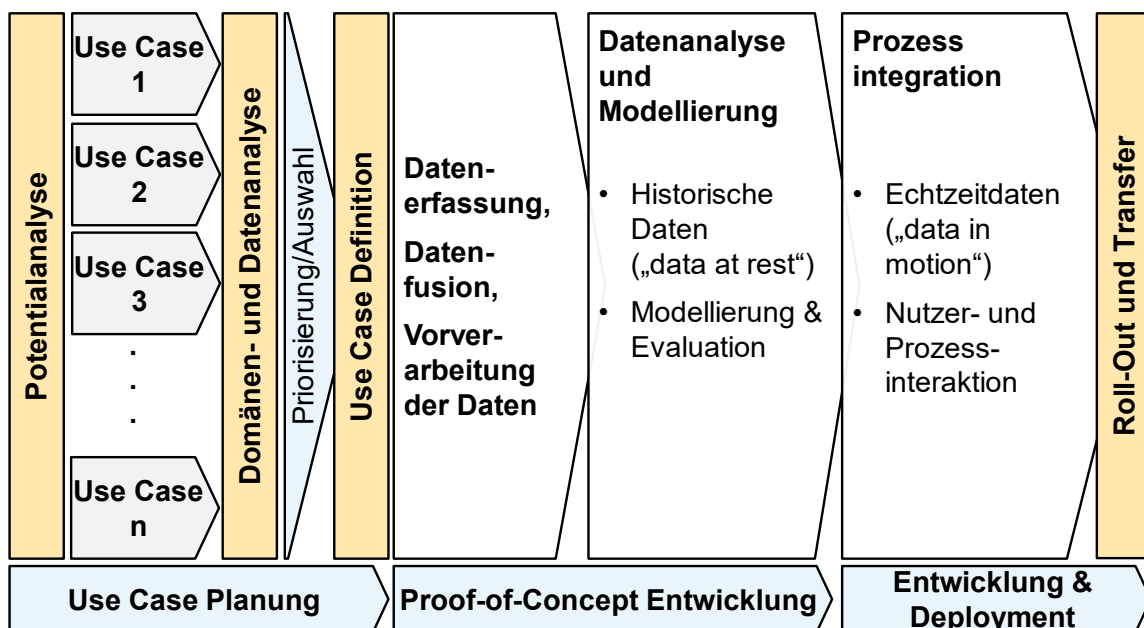


Bild 3-5: Vorgehensmodell für die Implementierung von Predictive Analytics Use Cases nach VON ENZBERG ET AL. [ENM+20, S. 2]

Der Prozess wird in die **Use Case Planung, Proof-of-Concept Entwicklung** sowie **Entwicklung und Deployment** eingeteilt. Eingangsgröße in den Prozess ist eine **Potenzialanalyse**. Aus der Potenzialanalyse werden Use Cases abgeleitet, spezifiziert und priorisiert. Die ausgewählte Menge an Use Cases wird umgesetzt und die Prozessintegration in Form eines **Piloten** vorgedacht. Der Prozess endet mit dem **Roll-Out und Transfer** (z. B. zu anderen Standorten).

**Bewertung:** Der beschriebene Ansatz nach VON ENZBERG ET AL. fokussiert sich auf Predictive Analytics Use Cases. Über die Phasen der Planung, Entwicklung und des Deployments werden die Phasen des CRISP-DM mit einzelnen Aspekten eines übergeordneten Vorgehens rekombiniert (Potenzialanalyse, Priorisierung und Auswahl, Prozessintegration). Neben dem übergeordneten Vorgehen werden vereinzelt stakeholderspezifische Perspektiven vorgeschlagen (CONSENS-Modelle, Integration in die IT). Deren Verwendung ist aber lose verankert und nicht systematisch in das Vorgehen integriert. Übergeordnet ist der Ansatz als Blaupause zur Anregung geeignet, welche Perspektiven für die Entwicklung von Prescriptive Analytics Use Cases für die Integration und Konzeption verwendet werden können.

### 3.2 Unterstützung der Konzeption von Prescriptive Analytics Use Cases

Die folgenden Ansätze lassen sich im **Handlungsfeld** „Konzeption von Prescriptive Analytics Use Cases“ verorten. Dieses Handlungsfeld fasst Ansätze zusammen, welche in Form von Artefakten die Konzeption von Analytics (und im spezifischen Prescriptive Analytics) Use Cases unterstützen. Der Konkretisierungsgrad nimmt mit den vorgestellten Ansätzen zu. Tabelle 3-1 gibt einen Überblick zu relevanten Artefakten zur **Konzeption von Analytics Use Cases** im Produktionskontext. Die Tabelle stammt aus der Vorveröffentlichung [EWB+24], welche auf der *CIRP CMS* vorgestellt wurde. Der Autor der Ausarbeitung hat an dieser Veröffentlichung maßgeblich mitgewirkt.

Tabelle 3-1: Artefakte zur Konzeption von IDS Use Cases aufbauend auf [EWB+24]

CRISP-DM Phase	Artefakt	Kurze Erläuterung
<b>Business Understanding</b>	Business to Analytics Canvas (B2A Canvas)	<ul style="list-style-type: none"> <li>Die Verwendung von Canvases bietet generell einen Mehrwert für die Strukturierung von Sachverhalten mit dem Vorteil der Wiederverwendbarkeit im Unternehmen. Dies wird für Prescriptive Analytics von SHTEINGART ET AL. [SOL+22] und für Data Science Projekte allgemein von LANGER UND SCHIRRMACHER [LS24] aufgegriffen.</li> <li>Die B2A Canvas ist eine Workshop-Vorlage, die systematisch Geschäftsfragen, Datenanalyseaufgaben und Algorithmen für Analytics Use Cases in der strategischen Produktplanung einander zuordnet [PME+22].</li> </ul>

<b>Business Understanding</b>	Analytics Canvas	<ul style="list-style-type: none"> <li>Die Analytics Canvas ist eine Workshop Methode zur Konzeption von Analytics Use Cases, benötigten Fähigkeiten, IT-Ressourcen und Datenquellen [KJR+18].</li> </ul>
	Schalenmodell zur Kosten-Nutzen-Schätzung	<ul style="list-style-type: none"> <li>Das Schalenmodell beschreibt ein Vorgehensmodell und die Einflussfaktoren für die Investitionsentscheidung in Digitalisierungs-Use Cases in der Produktion [JLT+19].</li> </ul>
<b>Data Understanding</b>	Data Map	<ul style="list-style-type: none"> <li>Die Data Map ist eine Workshop Methode zur systematischen Identifizierung von für Analytics relevanten Daten, die in Geschäftsprozessen entstehen [JEK+19].</li> </ul>
<b>Data Preparation</b>	Framework für die domänenorientierte Vorverarbeitung von Sensordaten	<ul style="list-style-type: none"> <li>Das Framework dient der strukturierten Erfassung von für Process Mining relevanten Daten in der Produktion [BRE+23].</li> <li>Bereitstellung eines Konzepts zur Strukturierung von Nutzungsdaten aus intelligenten technischen Systemen für die Verwendung in Analytics Use Cases [PEM+22].</li> </ul>
<b>Übergeordnet</b>	KPI-Set der zukünftigen Produktion	<ul style="list-style-type: none"> <li>Die Autoren geben einen Überblick über 38 Industrie 4.0 Key-Performance-Indikatoren (KPIs) [JEG+19].</li> </ul>
	Prozessreferenzmodelle	<ul style="list-style-type: none"> <li>Prozessreferenzmodell zur Verwendung von Data Analytics in der strategischen Produktplanung [MWP+22].</li> <li>PAISE: Prozessreferenzmodell für den Einsatz von Systems Engineering zur Entwicklung von KI-Systemen [HSP+21].</li> </ul>
	Reifegradmodelle	<ul style="list-style-type: none"> <li>Es werden verschiedene Reifegradmodelle zur Beschreibung der Datenanalyse oder des Managements in Organisationen vorgeschlagen [KAT+22, BLB+23, RBD24].</li> </ul>
	Architekturbeschreibung	<ul style="list-style-type: none"> <li>Aus dem Blickwinkel der IT-Unternehmensarchitektur gilt the <i>Open Group Architecture Framework (TOGAF)</i> als Quasistandard [Togaf10]. Weitere Frameworks wie das <i>Zachman Framework</i> (vgl. [Zac87]) oder aus dem militärischen Kontext entsprungene Frameworks (vgl. Aufzählung in [Lan17, S. 29]) finden nur in instanzierter Form in vereinzelter Entitäten zur IT-Unternehmensarchitekturbeschreibung Anwendung [IEC42010, S. 16].</li> <li>Einnahme der Perspektive des ganzen Wertschöpfungssystems nach Schneider [Sch18].</li> <li>Modellierung von Smart Services nach Rabe [Rab19].</li> </ul>

Aus der vorliegenden Tabelle wurden vier relevante Ansätze ausgewählt, um diese im Rahmen des Stands der Technik der Ausarbeitung zu disputieren. Die Ansätze wurden neben der Eignung in Bezug auf die Anforderungen der Ausarbeitung anhand der adressierten Architekturdimensionen und der Eignung für Prescriptive Analytics Use Cases ausgewählt. Eine **Einordnung der Ansätze nach ihren adressierten Architekturbenen** (siehe Kapitel 2.5.5) im Unternehmen wird in Bild 3-6 vorgenommen.

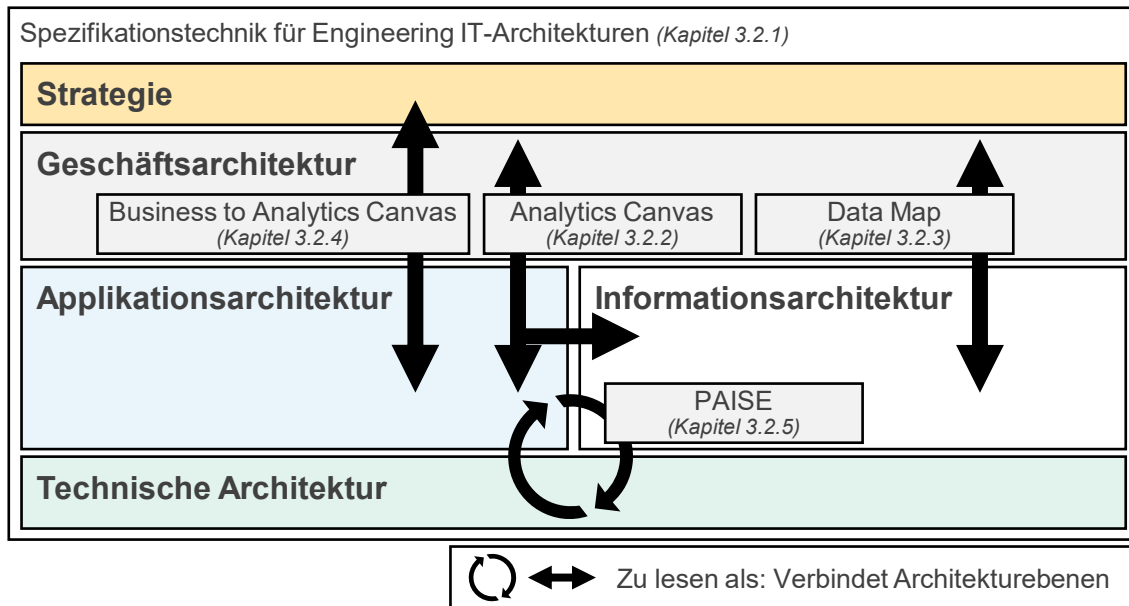


Bild 3-6: Einordnung der ausgewählten Ansätze zur Konzeption von Analytics Use Cases in den Unternehmensarchitekturebenen aufbauend auf Kapitel 2.5.5 (dargestellte Ansätze: [PME+22, KJR+18, JEK+19, HSP+21])

In **Kapitel 3.2.1** wird eine Spezifikationstechnik für Engineering IT-Architekturen nach HEIHOFF-SCHWEDE vorgestellt. Aufbauend darauf werden die Data Analytics Canvas nach KÜHN ET AL. in **Kapitel 3.2.2**, die Data Map nach JOPPEN ET AL. in **Kapitel 3.2.3**, die B2A Canvas nach PANZNER ET AL. in **Kapitel 3.2.4** und der PAISE Ansatz für das Systems Engineering von KI-Systemen nach HASTEROK ET AL. in **Kapitel 3.2.5** vorgestellt.

### 3.2.1 Spezifikationstechnik für Engineering IT-Architekturen nach HEIHOFF-SCHWEDE

Im Folgenden wird die **Spezifikationstechnik zur Analyse, Gestaltung und Bewertung von Engineering IT-Architekturen** nach HEIHOFF-SCHWEDE beschrieben [Hei24]. Diese Dissertation wurde im Rahmen der *HNI-Verlagsschriftenreihe* veröffentlicht. Der Ansatz wurde aufgrund des Bezugs zur IT-Architektur in produzierenden Unternehmen ausgewählt. Ergänzt wird das Modellierungskonzept der Spezifikationstechnik durch ein Vorgehensmodell sowie eine Werkzeugunterstützung (IT-Werkzeug und Kartenset). Der Ansatz ist vor allem auf Engineering IT-Architekturen zugeschnitten und kombiniert Ansätze aus dem Systems Engineering und EAM [Hei24, S. 99]. Der **Hauptwertbeitrag** der Dissertation ist ein Modellierungskonzept zur Beschreibung von Engineering IT-Architekturen. Der Ansatz fokussiert die Standardisierung und Harmonisierung von Perspektiven für die Spezifikation. Diese basiert auf Partialmodellen (vgl. Bild 3-7).

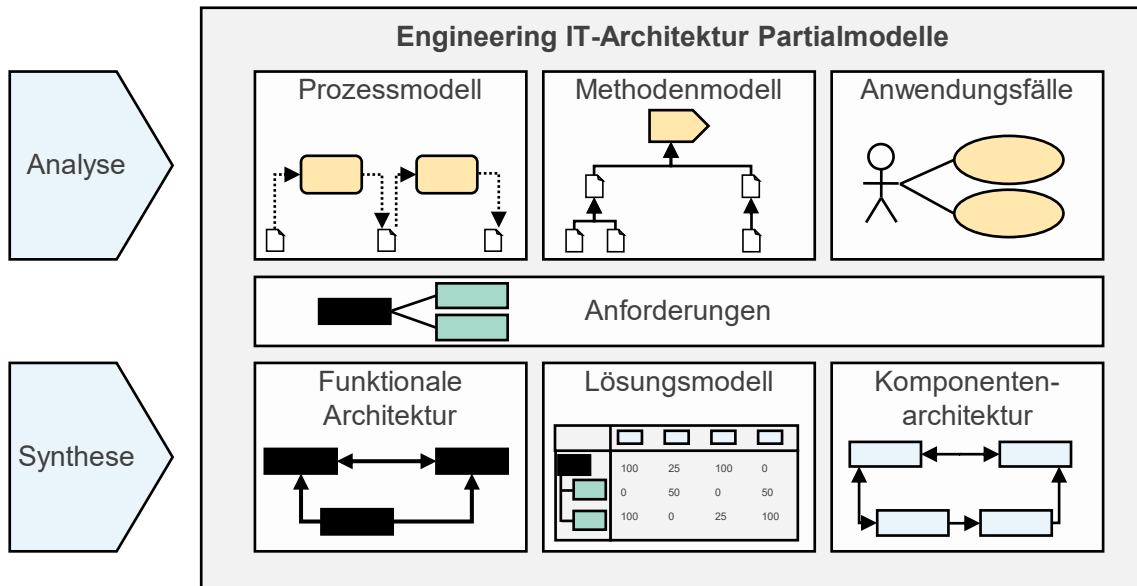


Bild 3-7: Partialmodelle der Spezifikationstechnik zur Analyse, Gestaltung und Bewertung von Engineering IT-Architekturen nach HEIHOFF-SCHWEDE [Hei24, S. 114]

Die Partialmodelle zur Beschreibung von **Engineering IT-Architekturen** bedienen die beiden übergeordneten Perspektiven der **Analyse** und **Synthese**. Zur Analyse werden ein **Prozessmodell**, **Methodenmodell** und eine **Anwendungsfalldarstellung** vorgeschlagen. Zur Synthese werden eine **funktionale Architektur**, ein **Lösungsmodell** sowie eine **Komponentenarchitektur** im Partialmodellkonzept verortet. Verbunden werden beide Perspektiven durch ein Partialmodell, welches die **Anforderungen** an die Analyse und Synthese der Engineering IT-Architekturen beschreibt [Hei24, S. 114].

**Bewertung:** Die Grundidee, Beschreibungsartefakte zur Planung, Konzeption und Integration von neuartigen Technologien, Lösungen oder Werkzeugen zu verwenden, wird in der Literatur vielfach aufgegriffen. Der Ansatz nach HEIHOFF-SCHWEDE definiert sinnvolle Perspektiven für die Analyse und Synthese bei der Gestaltung und Bewertung von Engineering IT-Architekturen. Es werden keine Prescriptive Analytics Spezifika berücksichtigt und die Methode ist nicht auf den Kontext der Produktion ausgelegt. Dementsprechend gilt es die Grundprinzipien zur Spezifikation aufzugreifen und mit existierenden Perspektiven auf die Entwicklung von Prescriptive Analytics Use Cases zu vergleichen.

### 3.2.2 Analytics Canvas für die Entwicklung von Data Science Anwendungen nach KÜHN ET AL.

Das Schichtenmodell (siehe Kapitel 2.3.1) dient zur Strukturierung von Analytics Use Cases in der Produktion mit dem Hauptziel, die Entwicklung der Use Cases an der Schnittstelle zwischen Domänenexperte, Management und Data Scientists effektiv zu gestalten. Dabei liegt ein Augenmerk auf der Strukturierung des ganzheitlich betrachteten

Use Cases in sogenannte Schichten. Das Modell befähigt zur interdisziplinären Diskussion von Data Analytics Ansätzen [RKD17]. KÜHN ET AL. erweitern das Schichtenmodell zur Anwendung in einem Workshopformat als **Analytics Canvas**. Sie ergänzen das Schichtenmodell um Standard-Notationselemente und eine Rollenzuordnung [KJR+18, S. 164]. Der Beitrag wurde auf der *CIRP Design* veröffentlicht. Der **Hauptwertbeitrag** der Autoren ist die Translation des Schichtenmodells in eine nutzbare Methode für ein Workshopformat (vgl. Bild 3-8).

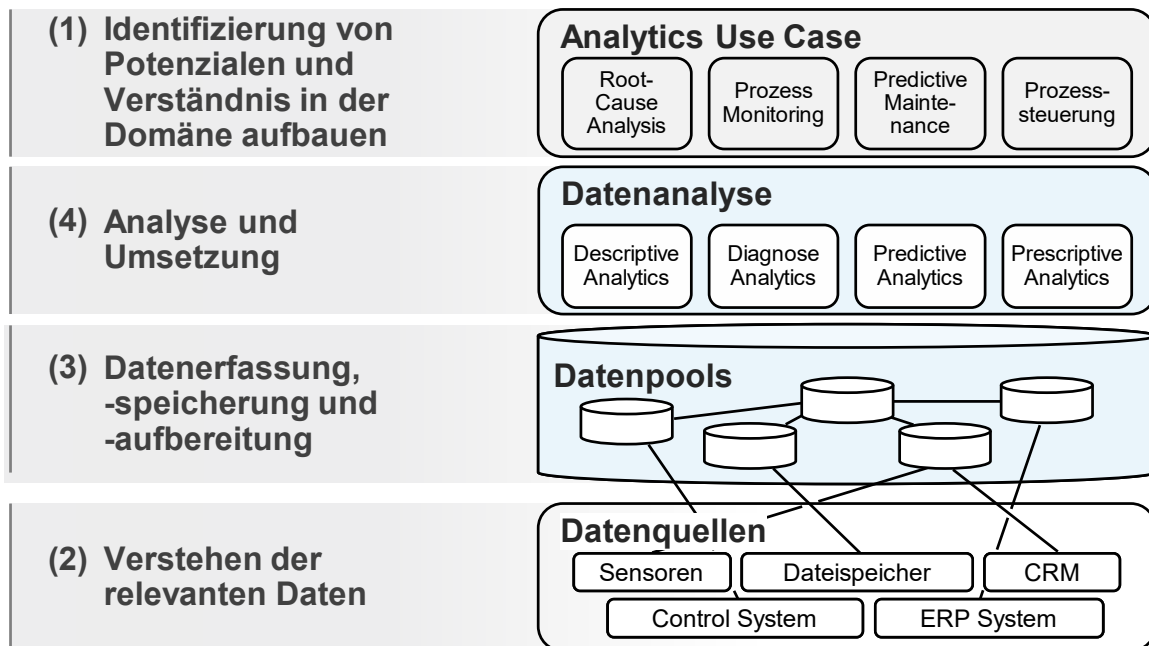


Bild 3-8: Beispielvorgehen der Verwendung der Analytics Canvas nach KÜHN ET AL. [KJR+18, S. 164]

Zur Anwendung der Data Analytics Canvas wird in einem ersten Schritt **Verständnis in der Domäne** aufgebaut und die **Identifizierung von Potentialen** für die Anwendung von Data Analytics angestoßen. Dafür werden zuerst die **Analytics Use Cases** (die entwickelt werden sollen) eingetragen. Im zweiten Schritt wird ein **Verständnis** der relevanten Daten aufgebaut. Die Data Analytics Canvas bricht dafür die Dimension Infrastruktur aus dem Schichtenmodell in **Datenquellen** und **Datenpools** Ebenen auf. Darauf basierend werden die vorliegenden Daten in der Produktion gesammelt und in der Datenquellen Ebene eingetragen. Dies geschieht im Schritt der Analyse der **Datenerfassung, -speicherung und -aufbereitung**. Final wird für die **Analyse und Umsetzung** einer initialen Use Case Architektur eine mögliche Technik zur Umsetzung (**Datenanalyse**) ausgewählt. Die Data Analytics Canvas fungiert somit als Artefakt zur semi-formalen Spezifikation singular betrachteter Use Cases. Eine Rollenzuordnung allokiert Manager, Data Scientists, IT-Experten und Domänenexperten in den jeweiligen Schichten. Ein Analytics Architekt fungiert als Bindeglied zwischen den anderen genannten Rollen.

Die Analytics Canvas wird beispielsweise im Vorgehen in [ENM+20] (siehe Kapitel 3.1.4) integriert und zur Erzeugung eines ersten Konzepts für einen Analytics Use Case verwendet.

MARTINEZ ET AL. haben in einer komparativen Analyse verschiedene Ansätze der Data Science Use Case Entwicklung verglichen [MVO21]. Die Analytics Canvas eignet sich nach MARTINEZ ET AL. besonders für das Design von Analytics Use Cases in frühen Phasen [MVO21, S. 8]. Es ist kein klarer Horizont für eine kontinuierliche Verwendung der Analytics Canvas über einen Use Case Lebenszyklus gegeben. Daten-, informations- und teambezogene Herausforderungen im Bereich der Data Science werden nur teilweise adressiert [MVO21].

**Bewertung:** Das Schichtenmodell sowie die Analytics Canvas weisen keinen Bezug zu Entscheidungen oder Entscheidungsprozessen (im allg.: Verankerung im Unternehmen) auf. Der Blick auf einen singulären Use Case ist weiterhin eine zu beachtende Einschränkung. Die Vernetzung von Use Cases oder die Wiederverwendung von Elementen innerhalb der Notation kann nicht ohne weiteres analysiert werden. Die Methode steht für sich und eine Einordnung oder Verwendung im Kontext anderer Methoden ist nicht gegeben. Trotzdem eignet sich insbesondere der Workshopcharakter gut zur Applikation der Methode in interdisziplinären Projekten im Produktionskontext.

### 3.2.3 Data Map zur Spezifikation von Datenflüssen in Produktionsumgebungen nach JOPPEN ET AL.

Die **Data Map** dient der semi-formalen Spezifikation von Datenflüssen und Prozessen [JEK+19]. Der Beitrag von JOPPEN ET AL. wurde auf der *CIRP ICME* veröffentlicht. Die Data Map fokussiert sich auf die systematische Erfassung relevanter Datenquellen und Datenflüsse sowie deren Grad der Digitalisierung entlang eines gegebenen Prozesses. Sie basiert auf einer Prozessaufnahme des betrachteten Geschäftsprozesses mit der *OMEGA Methode* (vgl. [Fah95]). Eine Kombination aus prozess- und ressourcenbezogener Sicht wird durch die Integration von Ressourcen und ihren Datenflüssen in den vorliegenden Prozess angestrebt [JEK+19]. Der **Hauptwertbeitrag** der Veröffentlichung ist die Workshopmethode zur Prozess- und Datenaufnahme. Das Ergebnis dient der Visualisierung von Informationsflüssen und dem Aufdecken von Data Analytics Potenzialen (vgl. Bild 3-9).

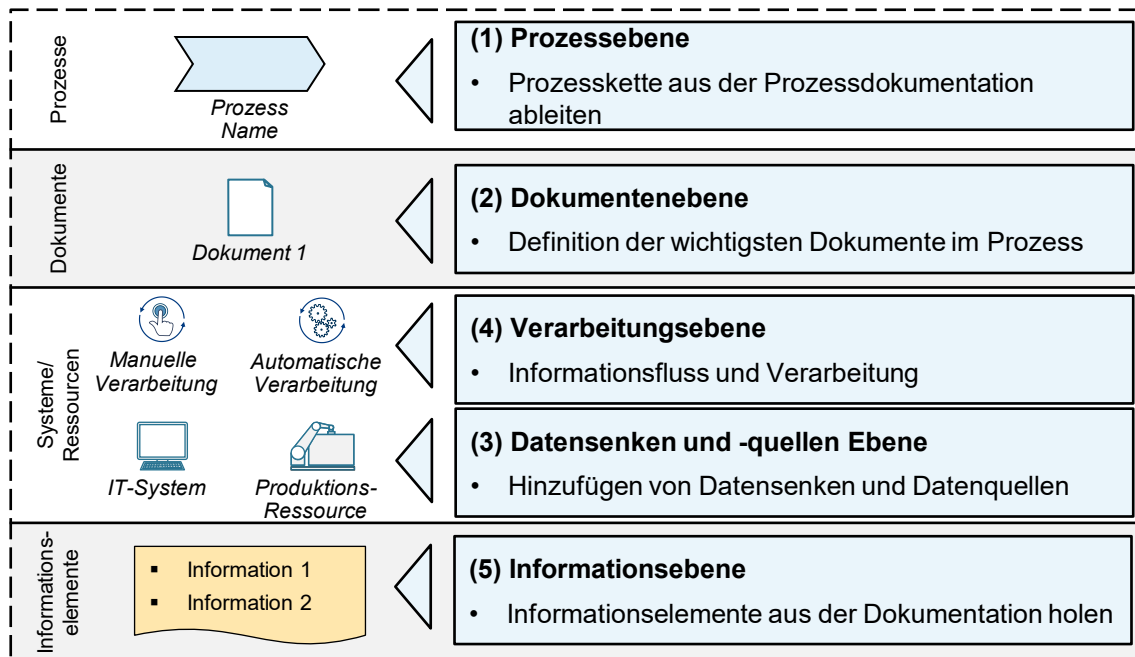


Bild 3-9: Anwendung der Data Map nach JOPPEN ET AL. [JEK+19, S. 464]

Die vier Modellierungsebenen ergeben sich wie folgt. Die **Prozessebene** stellt die Referenz zur Verknüpfung von Datenelementen durch den betrachteten Prozess dar. In der **Dokumentenebene** werden die relevanten Dokumente des jeweiligen Prozessschrittes gesammelt. Die Systeme und Ressourcen fassen die **Verarbeitungsebene** und **Datensenken sowie -quellen Ebene** zusammen. Diese dienen der Modellierung der vorhandenen IT-Systeme, Ressourcen und Dateneingabe- und Übertragungspunkte. Die unterste Ebene (**Informationsebene**) dient der Modellierung der gesuchten und relevanten Informationselemente. Das **Vorgehen** zur Modellierung kann Bild 3-9 entnommen werden. Die Autoren schlagen das Ableiten einer Matrix zur Analyse von Abhängigkeiten zwischen Datenpunkten und Dokumenten basierend auf den in der Data Map erlangten Erkenntnissen vor. Das abgebildete Vorgehen dient der Anwendung im Workshop. Dabei können vorhandene Datenpunkte aufgezeigt werden und so zur Analyse der IT-Bebauung entlang des Prozesses genutzt werden.

Die Data Map wird in die Systematik zur Bewertung von Industrie 4.0 Anwendungen in der Produktion zur Erfassung des Use Case Umfelds integriert (vgl. [Jop21, S. 126]). Neben der initialen Data Map wurde eine Reihe von Ausprägungen für verschiedene Sachverhalte entwickelt. So instanzieren BROCK ET AL. die Data Map zur Identifikation von Daten für das Process Mining (als einen Sonderfall der Industrial Data Science Komponenten) [BEK+23]. SCHREINER ET AL. nutzen das Grundkonzept zur Aufnahme von für Nachhaltigkeitsinitiativen relevante Daten (vgl. Nachhaltigkeits-Data Map [SKK+23]). Zur systematischen Aufnahme von Daten in Engineering Prozessen wird das Konzept von KÖDDING ET AL. und TISSEN ET AL. aufgegriffen (vgl. Engineering Data Map [KTK+23] und Systems Lifecycle Data Map [TWK+24]). Dementsprechend dient die

Data Map als Ausgangspunkt für eine sinnvolle Instanziierung für spezielle Domänenfragestellungen.

**Bewertung:** Die Data Map eignet sich hervorragend, um einen Überblick über vorhandene Datenpunkte sowie deren Synergien innerhalb eines Prozesses zu erlangen. Nachteile liegen in dem hohen manuell-schematischen Anteil des Aufnahmeprozesses der Elemente der Data Map. Dies kommt insbesondere bei verschachtelten Prozessen oder größeren Unternehmen zum Tragen. Durch die prozessbezogene Perspektive lässt sich keine direkte Verbindung zu einem Use Case ableiten. Weitere Perspektiven werden für einen ganzheitlichen Blickwinkel benötigt. Ein Prozess zur Etablierung oder Wiederverwendung der Spezifikation wird nicht bereitgestellt. Somit ergibt sich wie bei der Analytics Canvas kein klarer Ansatz zur Skalierbarkeit oder Integration in ein Projekt. Die Data Map ist insbesondere geeignet zur Initiierung von Data Analytics Projekten sowie für eingegrenzte kleinere Betrachtungsräume. Ein direkter Bezug zu Prescriptive Analytics Use Cases oder Spezifika in Bezug auf Entscheidungen in der Produktion sind in der Data Map nicht vorgesehen.

#### 3.2.4 Business to Analytics Canvas nach PANZNER ET AL.

Die **Business to Analytics Canvas** (B2A Canvas) adressiert die Übersetzung von business-getriebenen Fragestellungen in Lösungsansätze aus der Data Science Perspektive [PME+22]. Der Beitrag von PANZNER ET AL. wurde auf der *CIRP Design* veröffentlicht. Der Fokus liegt auf der Anwendung von Data Analytics in der strategischen Produktplanung. Neben einer Canvas zur Use Case Spezifikation wird auch ein Vorgehen für einen Workshop in der Veröffentlichung vorgestellt [PME+22]. Der **Hauptwertbeitrag** der Veröffentlichung ist eine Canvas zur Ermittlung von Descriptive, Diagnostic oder Predictive Analytics Use Cases für die strategische Produktplanung (vgl. Bild 3-10).

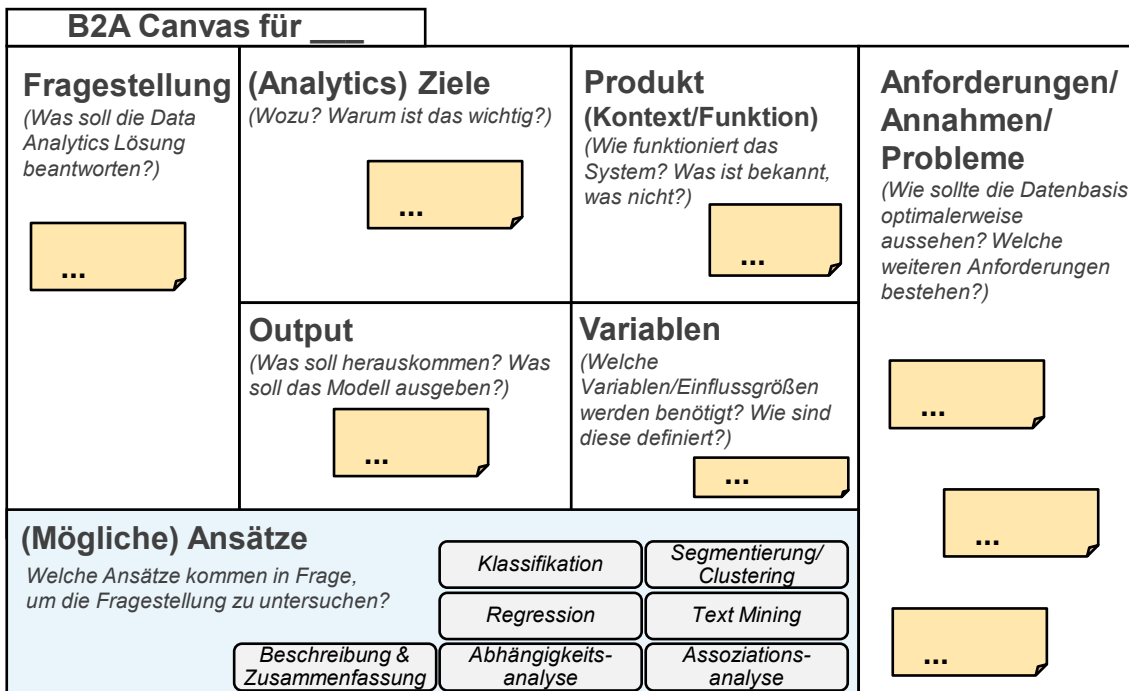


Bild 3-10: Business to Analytics Canvas nach PANZNER ET AL. [PME+22, S. 5]

Im Rahmen eines interdisziplinären Workshops (mit Produktmanagern und Data Scientists) wird zuerst die vorliegende **Fragestellung** für einen gewählten Use Case beschrieben. Darauf basierend werden die Elemente, die die Fragestellung beschreiben (**Ziele, Funktionen, Output, Variablen**) gemeinsam erarbeitet. Auf der rechten Seite der Canvas werden die zugrundeliegenden **Anforderungen, Annahmen** und **Probleme** gesammelt. Final werden **mögliche Lösungsansätze** basierend auf den Workshopergebnissen ausgewählt.

Ein als graue Literatur von SHTEINGART ET AL. veröffentlichter Beitrag stellt ein ähnliches Konzept für den Bereich der Prescriptive Analytics aus Operations Research Perspektive im Softwarebereich zur Verfügung [SOL+22]. Die Canvas fokussiert sich auf die Definition des Use Cases und die Auswirkungen eines Operations Research basierten Ansatzes [SOL+22, S. 5]. Weiterhin haben LANGER UND SCHIRRMACHER das Konzept von PANZNER ET AL. aufgegriffen und für allgemeine Data Analytics Projekte abstrahiert [LS24, S. 368].

**Bewertung:** Die Business to Analytics Canvas fokussiert sich auf eine andere Domäne und ist somit stark ausgerichtet auf Aspekte der strategischen Produktplanung. Prescriptive Analytics Aspekte wurden nicht mitgedacht und die genannten möglichen Ansätze haben nur eine bedingte Haltbarkeit (vgl. technischer Fortschritt z. B bei generativer KI [JCL+23]). Die Canvas ist stark eingeschränkt auf vorgegebene Lösungsbausteine. Daher ist sie schwer auf andere Ansätze oder Technologien zu übertragen. Das Grundkonzept ist aber etabliert und kann für die identifizierten Anforderungen der Problematik angepasst werden. Insbesondere der Aspekt der Übersetzung von einer Business Frage in eine

domänenspezifische Lösungsidee stellt einen spannenden Aspekt dar. Eine mögliche Integration in ein Lösungskonzept wird eruiert. Für die Ansätze nach SHTEINGART ET AL. und LANGER UND SCHIRRMACHER gilt die gleiche Kausalkette zur Herleitung der Bewertung. Beide Ansätze adressieren andere Umfelder und bieten wenig Hilfestellung bei der Umsetzung.

### 3.2.5 PAISE: Systems Engineering für KI-Systeme nach HASTEROK ET AL.

Das Prozessmodell für die Anwendung von **Systems Engineering für KI-Systeme (PAISE)** nach HASTEROK ET AL strukturiert die Entwicklung von KI-Systemen [HSP+21]. Der Beitrag wurde im *Competence Center for AI Systems Engineering* veröffentlicht. Es wird unterstützt durch mehrere Artefakte. Neben einem Rollenmodell werden detaillierte Hinweise zur Modularisierung von KI-Systemen zur Verfügung gestellt. Je Phase werden Leitfragen, Beispiele und Ergebnisse der Phase genannt. Nach HASTEROK ET AL. besteht ein KI-System aus mechanischen Subkomponenten, KI-Komponenten, Datensets und Befähiger-Systemen [HSP+21, S. 13]. Die Modularisierung dieser stellt die Grundlage des Systems Engineerings KI-basierter Systementwicklung dar [HSP+21, S. 7].

Der **Hauptwertbeitrag** der Veröffentlichung ist die übergeordnete Strukturierung der Dekomposition und Teildomänenentwicklung von KI-Systemen aus dem Blickwinkel des Systems Engineering (vgl. Bild 3-11).

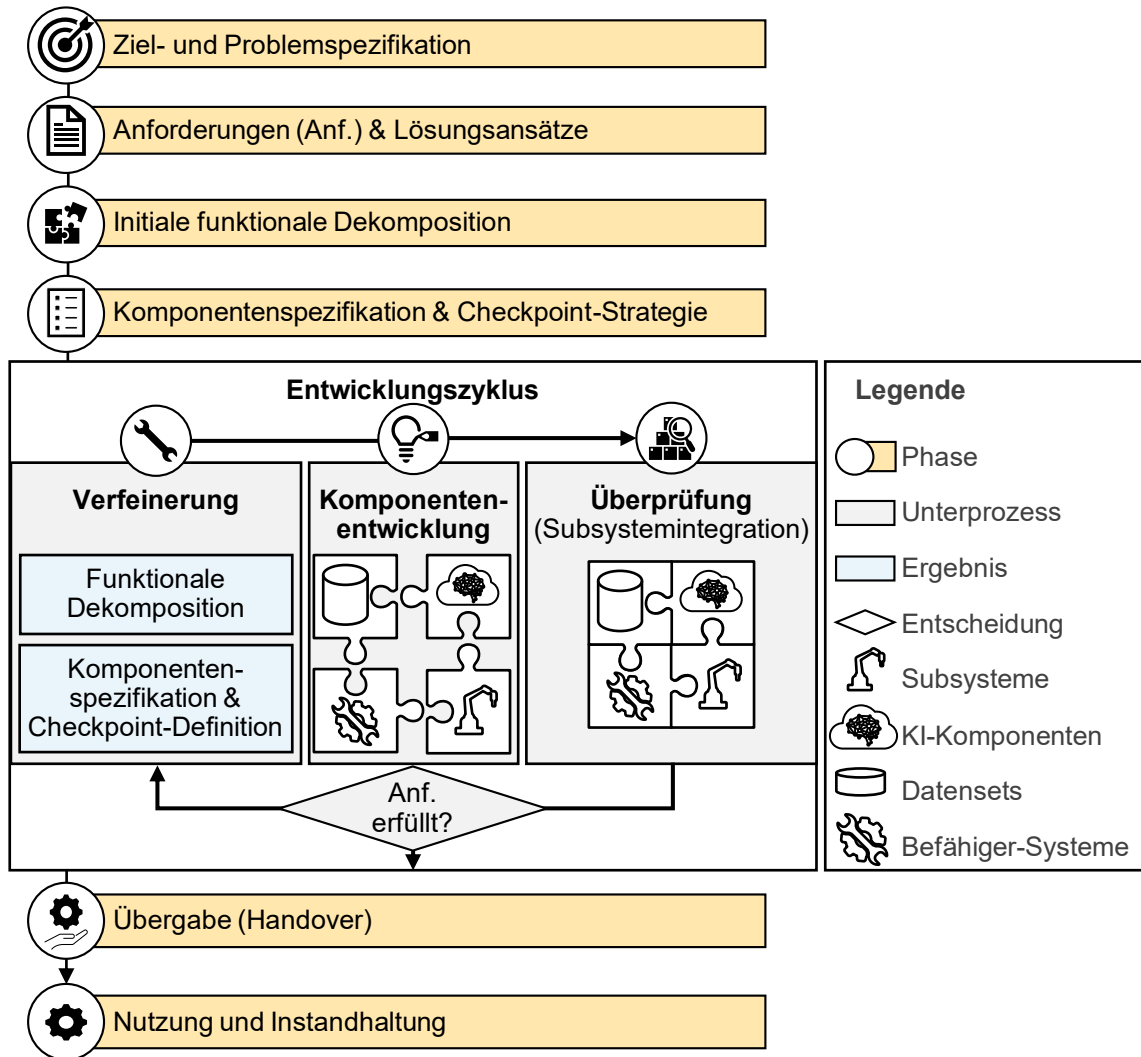


Bild 3-11: Schematische Übersicht über das PAISE Modell zur Systems Engineering basierten Entwicklung von KI-Systemen nach HASTEROK ET AL. [HSP+21, S. 7]

Das PAISE Vorgehensmodell beginnt mit einer **Ziel- und Problemspezifikation**. Basierend auf dieser werden **Anforderungen** erhoben und **mögliche Lösungsansätze** generiert. Die Lösungsansätze werden in ihre **Subkomponenten dekomponiert** (zerlegt). Die zerlegten Bestandteile des geplanten Systems werden weiter **spezifiziert** und **Checkpoints** bei der Entwicklung zwischen den einzelnen Subkomponenten festgelegt. Der darauffolgende **Entwicklungszyklus** ist iterativ. Zur Erfolgsmessung werden (die in der zweiten Phase aufgestellten) Anforderungen verwendet. Final wird das System **übergeben, genutzt und instandgehalten**.

**Bewertung:** Das PAISE Modell zur Systems Engineering basierten Entwicklung von KI-Systemen induziert einen hohen Grad an Komplexität in die Organisation von Entwicklungsprojekten und sieht ein lineares wasserfallartiges Vorgehen vor. Es ist primär ausgerichtet auf Produkte, nicht auf die Integration in existierende Systeme (der Produktion). Es setzt voraus, dass der Use Case („das KI-System“) bereits hinreichend eingegrenzt ist.

Weiterhin wird eine stark Systems Engineering getriebene Sicht propagiert, ohne die Besonderheiten von KI-Systemen zu berücksichtigen. Neben anekdotischen Beispielen wird kein Gestaltungswissen zur Unterstützung bei der Entwicklung bereitgestellt. Die Aspekte der Dekomposition des KI-Systems und die Integration der Ableitung von Anforderungen aus den Entwicklungszielen stellen sinnvolle Elemente dar. Weiterhin bietet das Vorgehen gute Leitlinien durch das Vorgeben von Synchronisationspunkten zwischen den Teilentwicklungsprojekten. Die Integration dieser Aspekte in ein Lösungskonzept sind zu prüfen.

### 3.3 Gestaltungswissen für Prescriptive Analytics

Die folgenden Ansätze lassen sich im **Handlungsfeld** „Gestaltungswissen für Prescriptive Analytics“ verorten, welches sich auf die Beschreibung der Spezifika von Prescriptive Analytics und Prescriptive Analytics Use Cases fokussiert. Eine Einordnung der Ansätze nach ihren adressierten Ebenen im Schichtenmodell nach REINHART ET AL. (siehe Kapitel 2.3.1) im Unternehmen wird in Bild 3-12 vorgenommen.

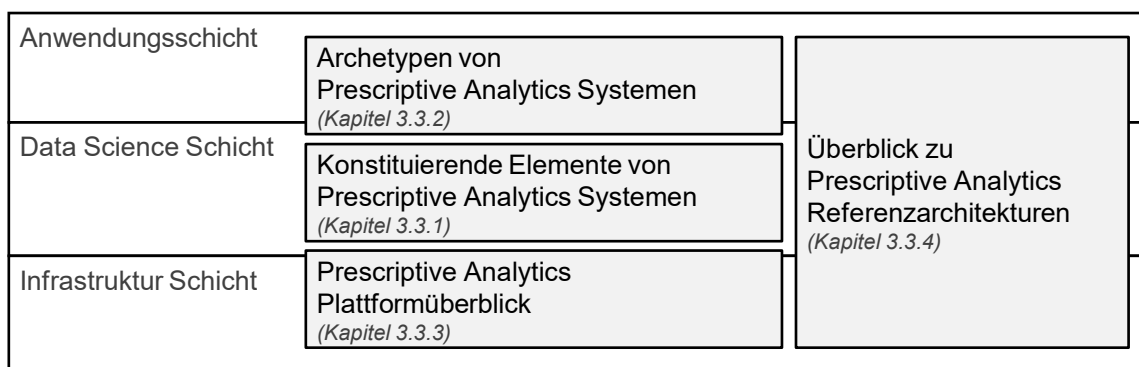


Bild 3-12: Einordnung der ausgewählten Ansätze mit Gestaltungswissen für Prescriptive Analytics Use Cases im Schichtenmodell aufbauend auf Kapitel 2.3.1 (dargestellte Ansätze: [WZ23, WZ24, NMW+24, WMN+24])

**Kapitel 3.3.1** gibt einen Überblick zu konstituierenden Elementen von Prescriptive Analytics Systemen dargestellt nach WISSUCHEK UND TSCHECH. Darauf aufbauend werden Archetypen für Prescriptive Analytics Systeme nach WISSUCHEK UND TSCHECH in **Kapitel 3.3.2** vorgestellt. Ein Überblick zu existierenden Vorarbeiten zu Prescriptive Analytics Plattformen nach NIEDERHAUS ET AL. und Prescriptive Analytics Referenzarchitekturen wird in **Kapitel 3.3.3** und **Kapitel 3.3.4** gegeben.

#### 3.3.1 Konstituierende Elemente von Prescriptive Analytics Systemen nach WISSUCHEK UND TSCHECH

Im Folgenden wird der Ansatz nach WISSUCHEK UND TSCHECH [WZ24] betrachtet. Dieser stellt eine Übersicht zu **konstituierenden Elementen von Prescriptive Analytics Systemen** bereit. Systeme beschreiben Use Cases, welche als entwickelte Lösungen in ihre

Umgebungen integriert sind (siehe Kapitel 2.1.4). Der Beitrag wurde im Journal *Information Systems and e-Business Management* veröffentlicht. Der Ansatz baut auf einer Veröffentlichung nach STEFANI UND TSCHECH [SZ18] auf. Dort wird mithilfe einer Konzeptmatrix ein Überblick zu den konstituierenden Elementen eines Prescriptive Analytics Systems abgeleitet [SZ18]. Der **Hauptwertbeitrag** ist die Systematisierung der Elemente von Prescriptive Analytics Systemen. Kern dieser Elemente ist die Ausführung der Prescriptive Analytics durch Agenten<sup>12</sup> [WZ24]. Es wird keine Einschränkung auf eine bestimmte Domäne vorgenommen. Die konstituierenden Elemente sind in Bild 3-13 dargestellt.

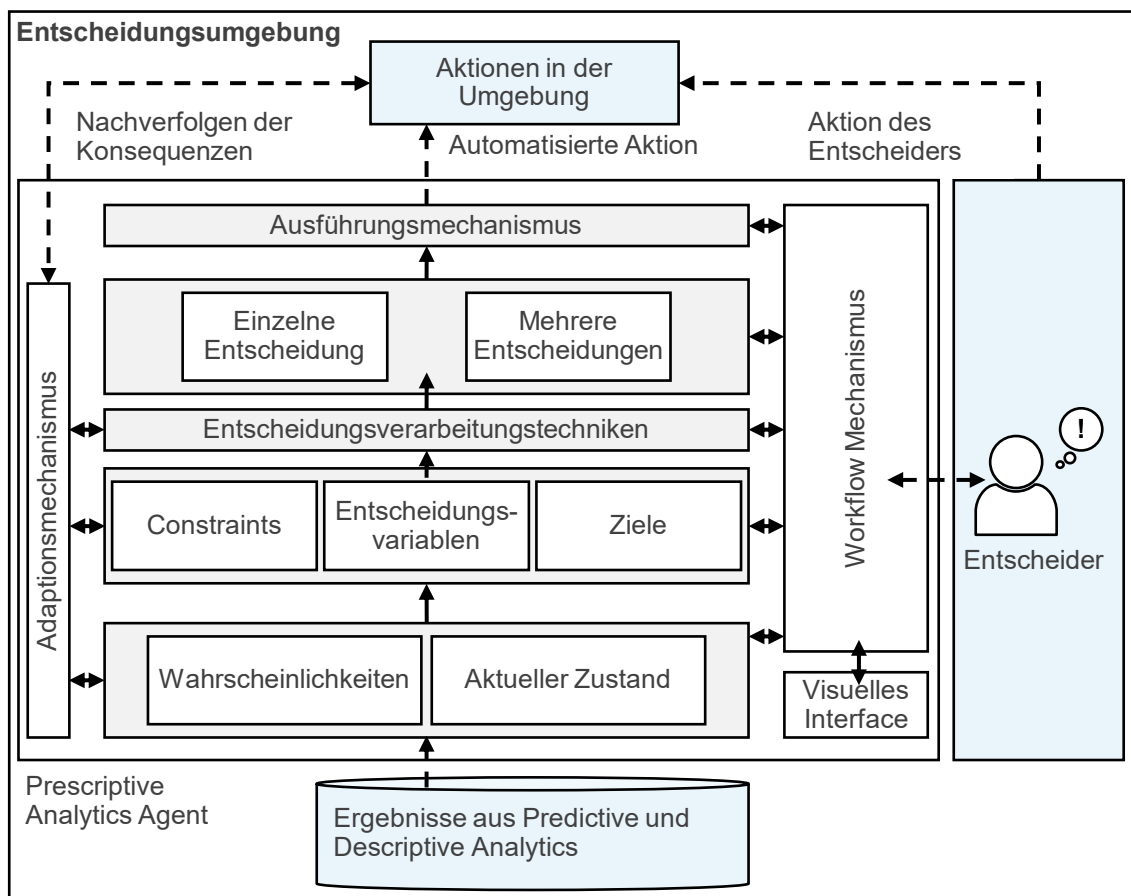


Bild 3-13: Konstituierende Elemente von Prescriptive Analytics Systemen nach WISSUCHEK UND TSCHECH [WZ24, S. 16]

Das Prescriptive Analytics System wird durch die **Entscheidungsumgebung** begrenzt. Es erzeugt **Aktionen in der Umgebung**. Im Zentrum stehen ein **Prescriptive Analytics Agent** sowie der **Entscheider**. Der **Agent** trifft **Entscheidungen**, dokumentiert die daraus resultierenden **Konsequenzen** und verarbeitet den Input anderer Analytics Ansätze

<sup>12</sup>Die Agententheorie und agentenbasierte Systeme stellen ein eigenes Forschungsgebiet dar. Der Einsatz von agentenbasierten Systemen für Prescriptive Analytics wurde zum Beispiel von ŠIKŠNYS ausführlich beleuchtet [Šik14, S. 189].

(**Ergebnisse aus Descriptive und Predictive Analytics**). Der Agent besteht aus verschiedenen Variablen, **Entscheidungsverarbeitungstechniken**, einem **Adaptionsmechanismus** und einem **Ausführungsmechanismus**. Dieser ist mit der Umgebung verbunden. Neben automatisierten Aktionen durch einen **Prescriptive Analytics Agenten** sind auch **Aktionen des Entscheiders** vorgesehen. Ein **visuelles Interface** dient der Kommunikation mit dem Entscheider über einen **Workflow Mechanismus**. [WZ24, SZ18]

**Bewertung:** WISSUCHEK UND TSCHECH stellen eine Übersicht zu den konstituierenden Elementen von Prescriptive Analytics Systemen aus einer Wirtschaftsinformatik-Perspektive bereit. Die Lösung ist rein literaturbasiert erarbeitet und wird in keinem realen Szenario zur Instanziierung verwendet. Für die Eignung zur Verwendung in der Spezifikationstechnik ergeben sich folgende Punkte. Die Lösung gibt einen guten Überblick, stellt aber keinen Bezug zur Integration und Konzeption für die Produktion bereit. Die Systeme werden als Insel konzipiert und es werden keine Schnittstellen zu anderen Entscheidungsprozessen vorgesehen. Dennoch stellt der generelle Aufbau einen guten Überblick bereit.

### 3.3.2 Archetypen von Prescriptive Analytics Systemen nach WISSUCHEK UND TSCHECH

Die Grundlagen für die **Archetypen für Prescriptive Analytics Systeme** wurden durch WISSUCHEK UND TSCHECH erarbeitet (vgl. [WZ23]). Der Beitrag wurde auf der *ECIS* veröffentlicht. Inhalt der Veröffentlichung [WZ23] sind Archetypen basierend auf einer systematischen Literaturrecherche. Es liegt kein Fokus auf eine bestimmte Domäne vor. Beispiele aus dem Produktionskontext werden zur Erläuterung verwendet. **Hauptwertbeitrag** ist die Destillation der Archetypen von Prescriptive Analytics Systemen aus der vorliegenden Literatur. Die vier Archetypen sind in Tabelle 3-2 zusammengefasst.

Tabelle 3-2: *Archetypen für Prescriptive Analytics Systeme nach WISSUCHEK UND TSCHECH [WZ23, S. 9] (PAS = Prescriptive Analytics System)*

Archetypen	Evaluation von Alternativen	Entscheidungs-träger	Adaption und Lernansatz
Informatives PAS	Automatisiert	Mensch	Statisch
Ausführendes PAS	Automatisiert	Maschine	Statisch
Adaptives PAS	Automatisiert	Mensch	Dynamisch
Autonomes PAS	Automatisiert	Maschine	Dynamisch

Alle Systeme bedienen sich einer automatisierten **Evaluation von Alternativen** als Entscheidungsgrundlage. Je nach System variieren der **Entscheidungsträger (Mensch/Maschine)** sowie der **Adaptions- und Lernansatz (statisch/dynamisch)**. In **informativen Prescriptive Analytics Systemen (PAS)** wird die Verantwortung für die Entscheidung durch den Menschen getragen. Das System besitzt keine Fähigkeit zu lernen oder adaptiv

zu reagieren. **Ausführende PAS** verlagern die Verantwortung für die Entscheidung an das System (Maschine). **Adaptive PAS** lassen den Menschen entscheiden, sind aber fähig aus der Rückmeldung zu lernen. **Autonome PAS** lernen dynamisch und verlagern die Entscheidung an das System (Maschine). Die Archetypen basieren auf einer Konzeptmatrix zu konstituierenden Elementen. Hier betonen die Autoren insbesondere die Integration von verschiedenen Entscheidungsmodi. [WZ23]

**Bewertung:** Die literaturbasierten Archetypen für Prescriptive Analytics Systeme nach WISSUCHEK UND TSCHECH geben einen guten Überblick zu möglichen Systemausprägungen bei der Umsetzung von Prescriptive Analytics Use Cases. Die Archetypen sind deskriptiver Natur. Aus der Einteilung einer Lösung in diese Kategorien lassen sich keine Maßnahmen oder Erkenntnisse direkt für die Entwicklung ableiten. Bei der Konzeption kann diese Übersicht bei Designentscheidungen zu Rate gezogen werden. Ein Transfer hin zum eigentlichen Use Case wird weiterhin benötigt.

### 3.3.3 Prescriptive Analytics Plattform-Überblick nach NIEDERHAUS ET AL.

In der Literatur gibt es bereits eine Vielzahl von Prescriptive Analytics Plattformen, welche das Konzept der Prescriptive Analytics mitdenken. Im Folgenden werden die Ergebnisse einer strukturierten Literaturanalyse zu **Prescriptive Analytics Plattformen** nach NIEDERHAUS ET AL. zusammengefasst [NMW+24]. Diese Vorveröffentlichung wurde auf der *FRUCT* als [NMW+24] veröffentlicht. Fokus der Recherche sind Analytics Plattformen im Kontext der Produktion, welche Aspekte von Prescriptive Analytics adressieren. Als Plattformen werden Konzepte verstanden, welche aus dem Blickwinkel der Applikationsarchitektur und technischen Architektur Software- und Hardwareelemente beschreiben, die dem übergeordneten Zweck der Ausführung bestimmter Programme dienen [Pie11, S. 179]. Nicht berücksichtigt werden sogenannte Frameworks. Frameworks sind wiederverwendbare Sammlungen von Werkzeugen, Bibliotheken und Standards. Sie geben Struktur vor und systematisieren vorgegebene Sachverhalte [Par23, S. 511].

**Hauptwertbeitrag** der strukturierten Recherche ist eine induktive Analyse der Eignung existierender Plattformen für Prescriptive Analytics Aspekte. Es werden Faktoren zur Entwicklung einer generischen Prescriptive Analytics Plattform abgeleitet. In Tabelle 3-3 wird ein Überblick über Prescriptive Analytics Plattformen durch eine Konzeptmatrix gegeben.

Tabelle 3-3: Übersicht zu Prescriptive Analytics Plattformen\* nach NIEDERHAUS ET AL. [NMW+24, S. 8]

Prescriptive Analytics Plattformen	Eingangsdaten						Protokolle				Datenbanken			Datentypen			Quelle	
	Prod. Mmt. Daten	Business Daten	Prozessdaten	Qualitätsdaten	Logistikdaten	Maschinendaten	MQTT	OPCUA	REST	weitere	SQL	NOSQL	HDFS	Vorverarbeitet	Historisch	Live	Edge	Cloud
[VSK20]	○	○	○	○	○	○	●	○	○	○	●	○	○	●	●	●	●	●
[VHK19b]	●	○	●	●	●	●	●	●	○	○	○	●	○	●	●	●	●	●
[PF21]	○	○	●	●	●	○	○	○	○	○	○	○	○	○	●	●	●	●
[BGB22]	○	○	○	○	○	●	○	○	○	●	○	○	●	○	○	●	○	○
[Grö18]	●	●	●	●	●	●	○	○	○	○	○	●	○	●	○	○	○	○
[FBH23]	○	○	○	○	○	●	○	○	○	○	○	○	○	●	●	●	●	○
[RPM+23]	○	○	○	●	○	○	○	○	○	○	○	○	○	○	○	○	○	○
[BPR+15]	○	○	○	○	○	○	○	○	○	○	○	○	○	●	●	○	○	○
[NK22]	○	○	○	○	○	●	○	○	○	○	○	○	○	○	●	○	○	○
[Hen20]	○	○	○	○	○	○	○	○	●	○	○	○	○	○	●	○	○	○
[MMO+20]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	●	○	○	○
[LBA+21]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	●	○	○	○
[SKY+23]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	●	○	○	○
[RNR22]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○
[AAB+20]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○
[MPH18]	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○

**Legende:**

○	nicht adressiert
●	adressiert

\* Abkürzungen können dem Abkürzungsverzeichnis entnommen werden

Die Matrix fasst zusammen welche Elemente in der jeweiligen Veröffentlichung in den untersuchten Plattformen berücksichtigt wurden. Folgende Schlussfolgerungen lassen sich aus der analysierten Literatur ziehen:

- **Fokus der Plattformen:** Die analysierten Plattformen zeigen eine starke Varianz in den Datenelementen und -quellen, die verarbeitet werden. Es werden etablierte Industriestandards verwendet. Es wurden keine Plattformen identifiziert, welche sich auf die Verarbeitung von Expertenwissen oder Entscheidungs- und Aktionswissen fokussieren. [NMW+24, S. 5]
- **Leistungsstufen von Prescriptive Analytics:** Keiner der untersuchten Ansätze geht über die Stufe Decision Augmentation (siehe Kapitel 2.4.1) hinaus. Der

Großteil der Ansätze fokussiert sich auf die Stufe „Empfehlung“. [NMW+24, S. 5]

Die Autoren schlussfolgern, dass zunehmend Interesse an der skalierbaren Implementierung von Prescriptive Analytics Ansätzen besteht. Dies äußert sich unter anderem in der steigenden Anzahl an Prescriptive Analytics Plattform Veröffentlichungen in den letzten vier Jahren. Vielmehr wird in vielen Fällen Prescriptive Analytics primär als Schlagwort verwendet, ohne dass eine tatsächliche Umsetzung einer Aktion (präskriptiver Charakter und Actionable Decision) erfolgt. Dies führt zu einer Diskrepanz zwischen dem antizipierten Fortschritt zu Prescriptive Analytics in der Forschung und der Anwendung in realen Use Cases [NMW+24, S. 6].

**Bewertung:** Der Beitrag zu existierenden Prescriptive Analytics Plattformen nach NIEDERHAUS ET AL. gibt einen Überblick zu existierenden Plattformen. Ausschlaggebend sind die Implikationen der Analyse der Plattformveröffentlichungen. Plattformkonzepte werden als Prescriptive Analytics Plattformen bezeichnet, sind im Kern aber allgemeingültige Data Analytics Plattformkonzepte. In keiner Veröffentlichung wird der Fokus explizit auf den Entscheidungs- und Aktionsraum (Prescriptive Analytics Besonderheiten) gelegt. Alle analysierten Plattformen bieten anekdotische Fallbeispiele. Diese bieten aber das Potenzial, abstrahiert zu werden. Es wird in der Regel kein Metamodell zur Beschreibung genutzt, sondern es werden einfach auf logischer Ebene funktionale Blöcke miteinander verbunden. Dies erschwert die Wiederverwendbarkeit und Übertragbarkeit. Neben der logischen Perspektive auf die Plattform werden keine weiteren Perspektiven bereitgestellt.

### 3.3.4 Prescriptive Analytics Referenzarchitektur-Überblick

In der Literatur gibt es bereits eine Vielzahl von veröffentlichten **Referenzarchitekturen**, welche das Konzept von Prescriptive Analytics mitdenken. Im Folgenden werden die Ergebnisse einer vorveröffentlichten strukturierten Literaturanalyse zusammengefasst. Diese wurde im MDPI Journal *Mathematics* als [WMN+24] veröffentlicht. Fokus der Recherche sind Analytics Referenzarchitekturen im Kontext der Produktion, welche Aspekte von Prescriptive Analytics (siehe Kapitel 2.4) adressieren.

**Hauptwertbeitrag** der Veröffentlichung ist die übergreifende Analyse existierender Referenzarchitekturen. In Tabelle 3-4 wird ein Überblick über die in Prescriptive Analytics Referenzarchitekturen in Form einer Konzeptmatrix gegeben. Die **Konzeptmatrix** ordnet den analysierten Referenzarchitekturen die **berücksichtigten Elemente** zu. Diese wurden induktiv aus den analysierten Referenzarchitekturen abgeleitet und haben keinen Anspruch auf Vollständigkeit. [WMN+24]

Tabelle 3-4: Übersicht zu verschiedenen Referenzarchitekturen mit dem Fokus auf Prescriptive Analytics [WMN+24, S. 8]

Referenz- architektur	Berücksichtigte Elemente der analysierten Referenzarchitekturen											
	Produktionsumgebung als eignes Element	Materialfluss	Cyber-physische Systeme (CPS)	Regelungstechnische Elemente	Systemschnittstellen (intern)	Daten Governance	Agentenbasierte Systeme	Eigener Prescriptive Analytics block	Allgemeine Data Analytics Aspekte	Human machine interface (HMI)	Übergeordnete IT-Systeme	Security Element
[DIN16]	○	○	○	○	◐	○	○	○	○	○	●	○
[FCC+23]	◐	●	●	●	●	○	○	○	●	○	○	●
[PPS+21]	○	○	○	●	●	○	●	○	◐	○	○	○
[MHB23]	○	○	○	○	◐	○	○	○	○	○	◐	○
[GMH23]	◐	◐	◐	◐	◐	○	○	○	○	○	◐	○
[ZM23]	◐	◐	◐	◐	◐	○	○	○	◐	○	●	○
[FHH+23]	◐	○	◐	●	●	○	○	◐	◐	○	○	○
[SGY+23]	●	○	○	●	●	●	○	○	◐	○	◐	○
[MWJ+21]	●	○	●	●	●	●	●	○	●	◐	●	●
[KAA+22]	●	◐	●	●	●	●	○	○	●	◐	●	●
[BLJ23]	◐	◐	◐	●	●	○	◐	○	◐	●	●	○
[FFL+22]	○	○	○	○	◐	●	○	○	●	○	○	○
[WSS+18]	●	○	●	◐	◐	◐	○	○	●	◐	●	◐
[KA23]	○	○	◐	●	●	●	○	○	●	●	◐	●
[GBM24]	○	○	○	○	◐	●	○	◐	●	●	●	○
[WST+20]	○	○	○	○	◐	●	○	◐	●	●	●	○

**Legende:**

○	nicht adressiert
◐	Teilweise adressiert
●	adressiert

Hervorzuheben ist ein starker Fokus auf Mensch-System und System-System Schnittstellen (**Interfaces**) innerhalb der Produktion. Weiterhin werden Aspekte wie **Security** und die einzelne Prescriptive Analytics Use Cases kaum berücksichtigt. **Prescriptive Analytics** als eigener Systemblock wurde nur in drei der Architekturen teilweise als Element genutzt. Folgende Schlussfolgerungen lassen sich aus der analysierten Literatur ziehen:

- **Adressierte Ebenen:** Die adressierten Elemente einer Architektur der untersuchten Referenzarchitekturen variieren stark. Oftmals wird die technische und Applikationsarchitektur adressiert (vgl. [RRW+22, WST+20]). Teilweise werden ausschließlich logische Elemente einer Architektur adressiert (vgl. [ZM23]).

- **Allgemeingültigkeit der vorgeschlagenen Lösung:** Keine der analysierten Referenzarchitekturen beinhaltet ein Instanziierungskonzept. Das heißt, dem Anwender wird die Übertragung auf den eigenen Anwendungskontext überlassen. Dies ist durch den hohen Grad an spezifischem Use Case Bezug der analysierten Referenzarchitekturen herausfordernd. So stellt beispielsweise die *PriMA Referenzarchitektur* nach ANSARI ET AL. einen spezifischen Ansatz für Prescriptive Maintenance dar, bietet aber keine Mechanismen zur Übertragung auf den eigenen Anwendungskontext [AGN19].
- **Abgrenzung zu Plattformkonzepten:** Viele Referenzarchitekturen sind den Plattformkonzepten aus Kapitel 3.3.3 ähnlich und dienen in der Regel eher der abstrahierten Beschreibung von Einzellösungen. So beispielsweise die Referenzarchitektur für Big Data Analytics nach VATER ET AL. [VHK19a].

**Bewertung:** Keine der untersuchten Plattformen entspricht den Anforderungen aus der Problemanalyse zur Integration von Prescriptive Analytics Use Cases in die Produktion. Weiterhin ist deren Evaluation oft mangelhaft beschrieben oder nur konzeptionell erfolgt. Vorgeschlagene Referenzarchitekturen sind überwiegend unvollständig oder adressieren nur bestimmte dedizierte Subsysteme und nehmen keine übergeordnete Perspektive ein. Somit ist die Übertragbarkeit auf andere Systeme der untersuchten Referenzarchitekturen gering. Insbesondere die Dimension der Integration von Prescriptive Analytics Use Cases in das existierende System wird von keiner Referenzarchitektur adressiert. Übergeordnet bietet die Recherche aber eine gute Grundlage zur Synthetisierung einer Referenzarchitektur aus den analysierten spezifischen Architekturen.

### 3.4 Bewertung und Handlungsbedarf

Die kritische Analyse des Stands der Technik anhand der Anforderungen der Problemanalyse (siehe Kapitel 2.7) ergibt die folgende Bewertung. Tabelle 3-5 stellt einen Überblick zum Vergleich der Anforderungen (eingeordnet in Handlungsfelder) und Ansätze aus dem Stand der Technik dar.

Tabelle 3-5: Bewertung des für die Ausarbeitung relevanten Stands der Technik anhand der aus der Problemanalyse resultierenden Anforderungen

Ansätze aus dem Stand der Technik			Anforderungen (A)							
<b>Bewertung</b> der untersuchten Ansätze hinsichtlich der gestellten Ziele  <b>Fragestellung:</b> Wie gut erfüllen die untersuchten Ansätze (Zeile) die gestellten Anforderungen zur Zielerreichung an eine <i>Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion</i> (Spalte)?			Anwendbar für produzierende Unternehmen	Unterstützung beim Management der Synergien zwischen Use Cases	Unterstützung beim Vorgehen der Konzeption von Prescriptive Analytics Use Cases	Berücksichtigung unterschiedlicher Perspektiven für Prescriptive Analytics	Definition von Schnittstellen mit der bestehenden Unternehmensarchitektur	Berücksichtigung der Integration zukünftiger Technologien	Unterstützung bei der Umsetzung neuer Prescriptive Analytics Use Cases	Analysierbare Zusammenhänge von Entscheidungen
○ = nicht erfüllt   ◐ = teilweise erfüllt   ● = voll erfüllt			A1	A2	A3	A4	A5	A6	A7	A8
Ganzheitliche Vorgehen	Industrie 4.0	Industrie 4.0 Einführungsstrategie nach MERZ	●	◐	●	○	○	○	◐	○
		Rollout-Planung für Smart Factory Use Cases nach BUDDE ET AL.	●	○	●	◐	○	○	◐	○
	Analytics	Planung für Mensch-KI-Kollaboration nach GABRIEL ET AL.	●	◐	◐	○	○	○	○	○
		Predictive Analytics Planungsvorgehen nach VON ENZBERG ET AL.	●	◐	◐	○	○	◐	○	○
Analytics Methodik zur Konzeption	Spezifikationstechnik für Engineering IT-Architekturen nach HEIHOFF-SCHWEDE		○	○	◐	◐	◐	◐	○	◐
	Analytics Canvas nach KÜHN ET AL.		●	○	◐	○	○	●	○	◐
	Data Map nach JOPPEN ET AL.		●	○	○	○	◐	○	○	◐
	B2A Canvas nach PANZNER ET AL.		●	○	◐	○	○	○	◐	○
	PAISE - Systems Engineering für KI-Systeme nach HASTEROKET AL.		○	○	◐	○	◐	○	○	○
Prescriptive Analytics Gestaltungswissen	Konstituierende Elemente nach WISSUCHECK ET AL.		○	○	◐	◐	◐	●	○	◐
	Archetypen für Prescriptive Analytics Systeme nach WISSUCHECK ET AL.		○	○	◐	◐	○	○	◐	○
	Prescriptive Analytics Plattformen nach NIEDERHAUS ET AL.		◐	○	○	◐	○	◐	○	○
	Prescriptive Analytics Referenzarchitekturen (aggregiert)		◐	○	○	○	◐	○	○	◐

#### Anforderung 1: Anwendbar auf produzierende Unternehmen

Um das richtige Maß an Granularität zu treffen, wird ein Konzept angestrebt, das auf den Bereich der Produktion anwendbar ist. Diese Anforderung wird von den Ansätzen aus dem Kontext Industrie 4.0 größtenteils berücksichtigt. Festzustellen ist jedoch, dass die Ansätze, die Gestaltungswissen enthalten, alle agnostisch entworfen sind. Die Instanziierung dieser Ansätze für die Produktion wirkt vielversprechend und wird im Folgenden

geprüft. Insbesondere die für die Konzeption von Prescriptive Analytics Systemen betrachteten Ansätze weisen keinen direkten Bezug zur Produktion auf.

### **Anforderung 2: Unterstützung beim Management der Synergien zwischen Use Cases**

Zur Sicherstellung eines vorteilhaften Aufwand-Nutzen-Verhältnisses bei der Auswahl von Prescriptive Analytics Use Cases müssen die Auswahl methodisch unterstützt und die Zusammenhänge zwischen den Use Cases gemanagt werden. Die Anforderung wird oberflächlich von den Vorgehensmodellen und Einführungsstrategien für Industrie 4.0 berücksichtigt. Ein detailliertes Vorgehen zur Überprüfung von Synergien und Schnittstellen oder Auswirkungen der Use Cases aufeinander wird in keinem Ansatz bereitgestellt oder vorgesehen.

### **Anforderung 3: Unterstützung beim Vorgehen der Konzeption von Prescriptive Analytics Use Cases**

Ein strukturierter Ansatz zur Konzeption von Use Cases ist erforderlich, um die Integration und das Zusammenspiel der verschiedenen Use Cases im Unternehmenskontext zu gewährleisten. Zu diesem Zweck können auch die vorgestellten Ansätze zur Beschreibung von Unternehmensarchitekturen verwendet werden. Diese Anforderung wird teilweise von den Ansätzen nach GABRIEL ET AL. und VON ENZBERG ET AL. berücksichtigt. Die Integration von Teilaspekten dieser Ansätze erscheint sinnvoll und ist zu prüfen. All diese Ansätze leisten zwar Teilbeiträge, trotzdem ist keiner der Ansätze für das vorliegende Vorhaben geeignet. Dies begründet sich in der hohen Abstraktion der vorgestellten Ansätze und dem fokussierten Gestaltungsobjekt.

### **Anforderung 4: Berücksichtigung unterschiedlicher Perspektiven für Prescriptive Analytics**

Für die Anwendung des Konzepts ist eine Verknüpfung von der strategischen mit der taktischen und operativen Ebene der Use Case Entwicklung erforderlich, um die Relevanz für die industrienaher Anwendung zu gewährleisten. Die Ansätze zur Beschreibung von Unternehmensarchitekturen stellen die richtigen Werkzeuge bereit. Keiner dieser Ansätze bringt aber die richtigen Perspektiven für Prescriptive Analytics Use Cases mit (siehe Kapitel 2.5.3). Teile dieser Perspektiven werden durch die Artefakte zur Konzeption in Kapitel 3.2.2 bis Kapitel 3.2.5 bereitgestellt und können für spezifische Perspektiven in ein neues Gesamtkonzept integriert werden.

### **Anforderung 5: Definition von Schnittstellen mit der bestehenden Unternehmensarchitektur**

Es ist es essenziell, die weitere Schaffung von Insellösungen bei neuen Use Case Entwicklungen in der Produktion zu verhindern. Dafür gilt es deren Integration in die Produktion sowie die Vernetzung mit anderen bereits implementierten und neuen Analytics

Use Cases zu unterstützen. Keiner der untersuchten Ansätze hat diesen Schritt im Fokus oder strukturiert ihn in wiederverwendbarer Art und Weise.

### **Anforderung 6: Berücksichtigung der Integration zukünftiger Technologien**

Ein zentrales Element, welches Prescriptive Analytics Use Cases von anderen Analytics Use Cases unterscheidet, ist der starke Fokus auf eine zu treffende Entscheidung. Das Element wird ergänzt durch die Forderung nach einer lösungsneutralen Ausgestaltung der Spezifikation. Aufgrund der Anforderungen wurden Ansätze, welche einen Überblick über aktuelle Umsetzungstechniken geben (vgl. [BLA+21, LBA+20]), nicht im Stand der Technik inkludiert. Die genannten Punkte werden von Ansätzen aus dem Bereich des Gestaltungswissens und den Artefakten zur Konzeption erfüllt. Diese Ansätze gilt es in ein übergeordnetes Konzept zu integrieren. Insbesondere die B2A Canvas und die analysierten Plattformen erfüllen diese Anforderung nicht. Trotzdem bieten diese aber das Potenzial, durch Abstraktion als sinnvolle Grundlage zu dienen.

### **Anforderung 7: Unterstützung bei der Umsetzung neuer Prescriptive Analytics Use Cases**

Die Umsetzungsmöglichkeiten bei der Konzeption spielen aufgrund ihrer Implikationen für die spätere Entwicklung eine große Rolle. Die für Analytics im Allgemeinen bereitgestellten Artefakte zur Konzeption bieten einen ersten guten Ausgangspunkt für die Entwicklung neuer Prescriptive Analytics Use Cases (Analytics Canvas, Data Map). Es gilt, die Artefakte um Aspekte für Prescriptive Analytics zu erweitern und den lösungsneutralen Charakter beizubehalten.

### **Anforderung 8: Analysierbare Zusammenhänge von Entscheidungen**

Prescriptive Analytics Use Cases können schwer einzeln betrachtet werden und sind oft eingebettet in einen komplexen **Entscheidungszusammenhang**. Diese Analyse kann werkzeunterstützt oder analog erfolgen. Ansätze wie Referenzarchitekturen haben im Kern das Ziel, diese Zusammenhänge mitzugestalten. Da keine geeignete Referenzarchitektur identifiziert wurde, gilt es diesen Punkt genauer zu analysieren. Kein Ansatz stellt Mechanismen für eine werkzeunterstützte Analyse bereit. Ein gemeinsames Metamodell über verschiedene Artefakte hinweg würde der Standardisierung für die werkzeunterstützte Analyse dienen. Auf ein solches beruft sich keiner der Autoren der betrachteten Ansätze.

Für die Entwicklung eines ganzheitlichen Vorgehens sind etablierte Ansätze vorhanden, in der Regel aber zu generisch für eine direkte Anwendung. Den höchsten Detaillierungsgrad enthalten die Ansätze nach VON ENZBERG ET AL. und GABRIEL ET AL. Diese gilt es im Folgenden zu berücksichtigen. Insbesondere für eine perspektivenspezifische Analyse von Analytics Use Cases gibt es bereits einige vielversprechende Ansätze. Hier sind die Analytics Canvas nach KÜHN ET AL. (siehe Kapitel 3.2.2) sowie die Data Map nach JOPPEN ET AL. (siehe Kapitel 3.2.3) hervorzuheben. Jedoch werden die Kernherausforderungen der einzelnen Handlungsfelder ohne eine Weiterentwicklung des Stands der Technik

(siehe Kapitel 2.6) nicht berücksichtigt. Übergeordnet lassen sich folgende Punkte ableiten:

- **Fokus auf die Domäne Produktion:** Keine adäquate Adressierung der Besonderheiten von Prescriptive Analytics (siehe Kapitel 2.1.3) in den Ansätzen aus Handlungsfeld eins und Handlungsfeld zwei.
- **Fokus auf die Technik Prescriptive Analytics:** Ansätze zur Beschreibung von Prescriptive Analytics sind primär technologiegetrieben und spezifisch für Sonderfälle (z. B. Prescriptive Maintenance).
- **Fehlende Ganzheitlichkeit:** Ansätze fokussieren sich auf das Erzeugen von Inseln. Synergieaspekte werden nach initialer Planung oder Konzeption nicht weiter betrachtet (siehe Kapitel 2.5.1).

**Fazit:** Keiner der betrachteten Ansätze aus dem Stand der Technik erfüllt die Anforderungen aus der Problemanalyse in vollem Umfang. Es kann keine triviale Kombination existierender Ansätze gebildet werden, um alle Anforderungen zu einem zufriedenstellenden Maße zu erfüllen. Insbesondere im Kontext der Anforderung 4 (Berücksichtigung verschiedener Perspektiven) bietet keiner der existierenden Ansätze einen ausreichenden Grundansatz. Dementsprechend ist der Bedarf zur Entwicklung einer *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* gegeben.



## 4 Spezifikationstechnik

Das folgende Kapitel stellt den Kern der Ausarbeitung dar. Es dient der strukturierten Darstellung der Erarbeitung der *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion*. Hauptziel der Erarbeitung der **Spezifikationstechnik** ist es, die Anforderungen aus der Problemanalyse zu erfüllen. Hierfür wird der Stand der Technik als Grundlage herangezogen. Im Kontext der Instanziierung der Forschungsmethode nach PEFFERS ET AL. (siehe Kapitel 1.3) stellt dieses Kapitel das finale Ergebnis der iterativen Design-Zyklen vor.

**Kapitel 4.1** gibt einen Überblick über die Hauptbestandteile der Spezifikationstechnik. Sie besteht aus einem Strukturierungsrahmen, Vorgehensmodell, Modellierungskonzept, Artefakten zur Unterstützung und einer Werkzeugunterstützung. Um die für die Spezifikationstechnik benötigten Grundlagen bereitzustellen, werden in **Kapitel 4.2** strukturierende Elemente für Prescriptive Analytics Use Cases eingeführt. In **Kapitel 4.3** wird das Vorgehensmodell genauer erläutert. Der Zusammenhang mit dem Modellierungskonzept und den Artefakten zur Unterstützung wird beschrieben. **Kapitel 4.4** erläutert das Modellierungskonzept im Detail. Dies beinhaltet eine strukturierte Sammlung an zusammenhängenden Partialmodellen. Die Artefakte, welche im Kontext des Vorgehensmodells zur Befüllung der Partialmodelle genutzt werden, werden in **Kapitel 4.5** erläutert. **Kapitel 4.6** umreißt die vorliegende Werkzeugunterstützung zur IT-gestützten Umsetzung des Modellierungskonzeptes. Es werden einzelne Beispiele aus dem Projekt *VIP4PAPS* (vgl. [Enz22]) zur einfacheren Erläuterung verwendet. Im Projekt wurde unter anderem ein Prescriptive Analytics Use Case zur Entscheidungsunterstützung bei der Wartung einer Roboterzelle in der IoT Factory Gütersloh erarbeitet.

### 4.1 Bestandteile der Spezifikationstechnik im Überblick

Übergreifendes Ziel der Spezifikationstechnik ist die Unterstützung der Entwicklung (Planung, Konzeption und Integration) von Prescriptive Analytics Lösungen für die Produktion. Die *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* gliedert sich in **fünf Hauptbestandteile**. Sie besteht aus einem **Strukturierungsrahmen**, einem **Vorgehensmodell**, einem **Modellierungskonzept** zur Abbildung von Konzeptionsständen und entsprechenden Artefakten zur Unterstützung des Konzeptionsvorhabens. Ergänzt wird dies durch eine **Werkzeugunterstützung**. Die Spezifikationstechnik fokussiert sich auf Prescriptive Analytics Use Cases. Das Vorgehensmodell strukturiert das übergeordnete Vorgehen. Zur Spezifikation der Ergebnisse im Vorgehen wird das Modellierungskonzept verwendet. Das Modellierungskonzept besteht aus Partialmodellen. Zur einfacheren Befüllung der Partialmodelle werden Artefakte (Workshopmethoden und Referenzen) bereitgestellt. Zur Operationalisierung wird eine Werkzeugunterstützung bereitgestellt. Ein Überblick über die relevanten Bestandteile ist Bild 4-1 zu entnehmen.

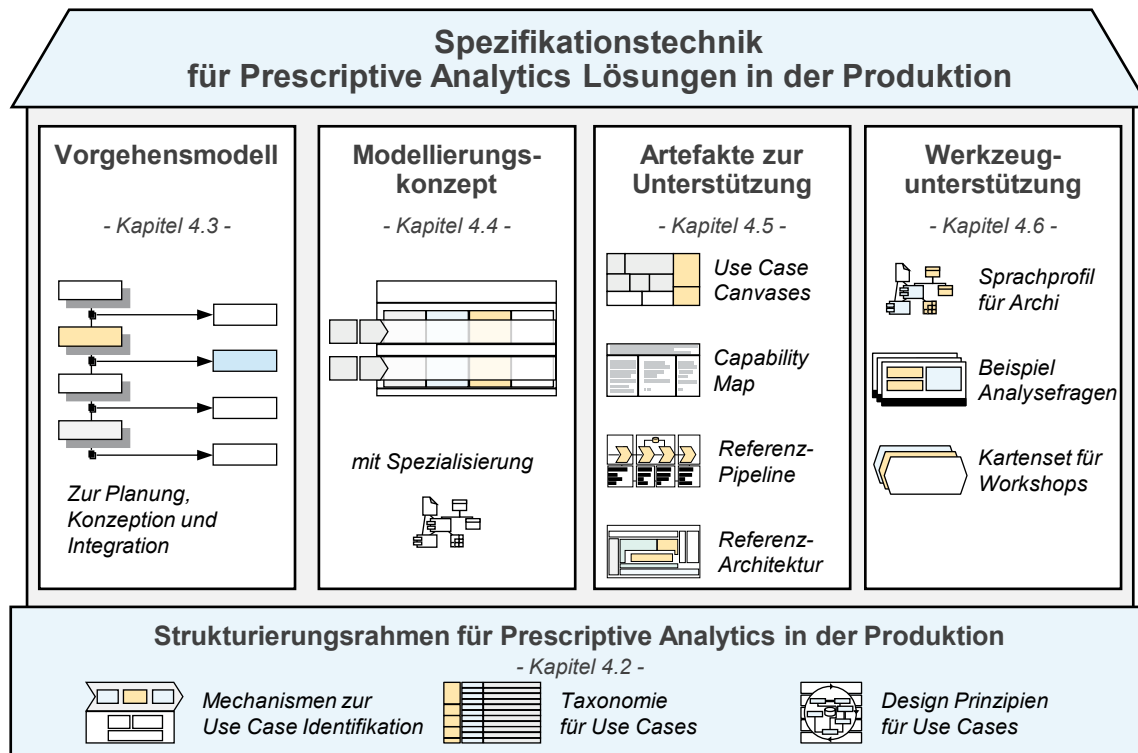


Bild 4-1: Die Spezifikationstechnik im Überblick

- Das übergeordnete **Vorgehensmodell** adressiert die Planung, Konzeption und Integration von Prescriptive Analytics Lösungen in der Produktion. Es strukturiert den Prozess in Phasen und Meilensteine mit Zwischenergebnissen. Relevante Tätigkeiten werden in eine sachlogische Reihenfolge gebracht.
- Zur Spezifikation der Entwicklungsstände wird im Vorgehensmodell ein **Modellierungskonzept** verwendet. Das Konzept dient dem schrittweisen Aufbau eines Gesamtmodells des betrachteten Systems. Dabei strukturiert es elf für die Konzeption benötigte Partialmodelle und dient der übergreifenden Organisation und Vernetzung von Teillösungen der Konzeption. Es stellt somit das Rückgrat der Anwendung der erarbeiteten Artefakte in der Spezifikationstechnik dar. Die Partialmodelle im Modellierungskonzept werden durch eine Spezialisierung des *ArchiMate* Metamodells verknüpft.
- Die **Artefakte zur Unterstützung** dienen der Befüllung der Partialmodelle und der effektiven Ausführung des Vorgehensmodells. Die Artefakte befähigen somit die effiziente Nutzung des Modellierungskonzepts im übergeordneten Vorgehensmodell. Sie bestehen aus einer Canvas zur Use Case Transformation, einer Canvas zur Spezifikation der benötigten Daten, eine generische Capability Map zur Instanziierung sowie einer Referenzpipeline und -architektur.
- Die **Werkzeugunterstützung** unterstützt die Methode und Sprache der Spezifikationstechnik durch eine geeignete IT-Lösung. Hierbei wird aufbauend auf dem Programm *Archi* ein Sprachprofil für *ArchiMate* zur Verfügung gestellt. Es werden beispielhafte Analysefragen zur Analyse des Gesamtmodells bereitgestellt.

Ein Kartenset für Workshops dient der Unterstützung bei analogen Workshopformaten.

- Der **Strukturierungsrahmen** dient der Unterstützung der *Spezifikationstechnik* mit Grundlagenwissen zur Ausgestaltung und zum Verständnis des komplexen Themas. Er besteht aus Mechanismen zur Identifikation, einer Taxonomie und Design Prinzipien für Prescriptive Analytics Use Cases in der Produktion.

Das Vorgehensmodell sowie das Modellierungskonzept könnten auch generell für Advanced Analytics Use Cases eingesetzt werden. Jedoch sind die Wissensbasis auf der aufgebaut wird sowie die Demonstration und Evaluation, auf Prescriptive Analytics Lösungen zugeschnitten. Dies trifft besonders auf die erarbeiteten Artefakte zur Unterstützung zu. Ein Übertrag der Bestandteile der Spezifikationstechnik auf andere Kontexte und Analytics Use Cases wird in Kapitel 5.2 diskutiert.

## 4.2 Strukturierung von Prescriptive Analytics in der Produktion

Unternehmen benötigen Unterstützung bei der Identifikation von relevanten und praxistauglichen Analytics Use Cases in der Produktion [WHD24, S. 16]. Um diesem Bedarf gerecht zu werden, wird im Folgenden die Identifikation und Klassifikation von Use Cases näher beleuchtet. Dies dient der übergeordneten **Strukturierung von Prescriptive Analytics in der Produktion**.

**Kapitel 4.2.1** gibt einen Überblick zu möglichen Mechanismen zur Analytics Use Case Identifikation. Diese helfen bei der initialen Identifikation von Use Cases. Darauf aufbauend werden in **Kapitel 4.2.2** eine Taxonomie für Prescriptive Analytics Use Cases sowie in **Kapitel 4.2.3** Design Prinzipien für Prescriptive Analytics Use Cases vorgestellt. Die Taxonomie unterstützt bei der Charakterisierung identifizierter Use Cases. Die Design Prinzipien helfen bei der Konzeption und Ausgestaltung des Use Cases.

### 4.2.1 Mechanismen zur Analytics Use Case Identifikation

Die Identifikation und Erarbeitung von Prescriptive Analytics Use Cases ist keine triviale Aufgabe (siehe Kapitel 2.4.1). Zur Unterstützung der Aufgabe wird eine Übersicht mit **Mechanismen zur Analytics Use Case Identifikation** bereitgestellt. Sie dient als Übersicht wie eine initiale Menge an Prescriptive Analytics Use Cases ermittelt werden kann. Die Erarbeitung ist literaturbasiert erfolgt.

In Kapitel 2.5.2 der Problemanalyse wurden verschiedene Mechanismen zur Identifikation und Charakterisierung von Analytics Use Cases vorgestellt. Die Strukturierung dient als Übersicht zu den Mechanismen wie eine initiale Menge an Prescriptive Analytics Use Cases ermittelt werden kann. Die Ausarbeitung unterstützt generell alle Mechanismen, um Prescriptive Analytics Use Cases zu ermitteln. Aufbauend auf diesen ergibt sich die Übersicht in Bild 4-2.

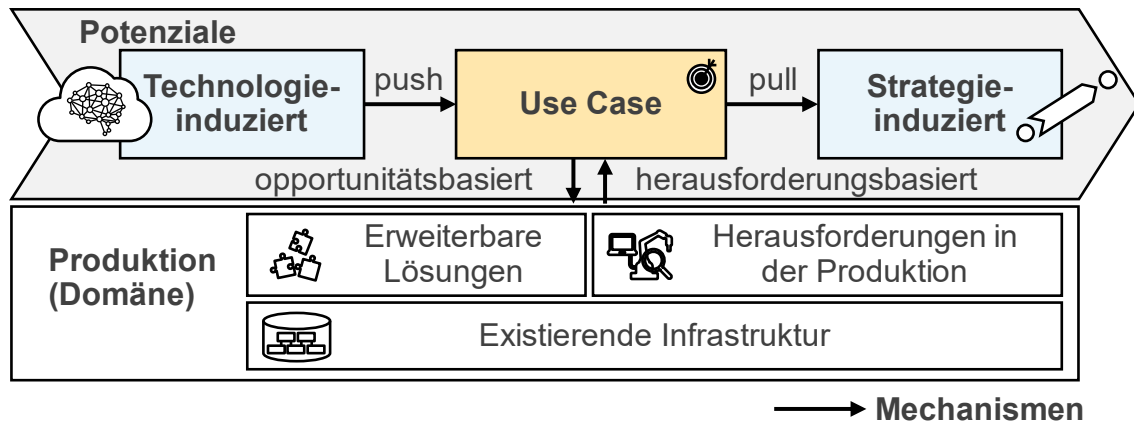


Bild 4-2: Mechanismen zur Use Case Identifikation für die zielgerichtete Identifikation von Analytics Use Cases in der Produktion aufbauend auf Kapitel 2.5.2

In der Praxis hat sich gezeigt, dass insbesondere die **herausforderungsbasierten** und **opportunitätsbasierten Mechanismen** am vielversprechendsten sind (siehe Kapitel 2.5.2). Diese bauen auf Voraussetzungen in der **Domäne der Produktion** auf. Dazu zählen **erweiterbare Lösungen**, ungelöste **Herausforderungen in der Produktion** oder **existierende Infrastruktur**. Allerdings muss mit jedem Use Case die Übereinstimmung mit den strategischen Zielen geprüft werden. Insbesondere **strategie-** und **technologieinduzierte** Use Cases sind einer kritischen Überprüfung zu unterziehen. Diese Use Cases unterliegen den Mechanismen von **Push** und **Pull**.

Die ermittelten Use Cases müssen für die Umsetzung in eine Lösung näher betrachtet werden. Jeder Analytics Use Case kann um Prescriptive Analytics Aspekte erweitert werden (siehe Kapitel 2.4.1). Sollte dies mit bereits implementierten Use Cases im betrachteten Umfeld nicht geschehen sein, können diese transformiert werden. Prescriptive Analytics Use Cases müssen unternehmensspezifisch instanziiert und in Lösungen transformiert werden. Aus den Mechanismen aus Bild 4-2 lassen sich übergeordnete Use Cases ableiten. Diese gilt es in einem Projekt zu einer **Lösung** zu konkretisieren.

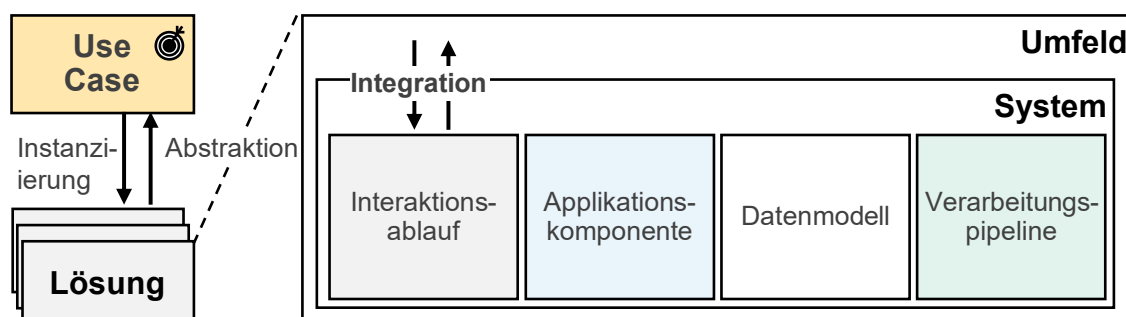


Bild 4-3: Transformation von Analytics Use Cases in integrierte Lösungen im Produktionsumfeld aufbauend auf Kapitel 2.5.5

In der Ausarbeitung wird im Folgenden von Use Cases gesprochen. Bei erfolgreicher Umsetzung und Integration eines Systems in sein Umfeld, welches auf einem Use Case basiert, resultiert daraus eine Lösung. Als **Lösung** wird im Folgenden ein instanziiertes **Use Case** mit definiertem **Interaktionsablauf** mit dem Nutzer (z. B. Frontend), definierten **Applikationskomponenten**, definiertem **Datenmodell** und definierter **Verarbeitungspipeline** beschrieben. Das daraus resultierende **System** muss in das Umfeld des Unternehmens integriert werden (vgl. Bild 4-3).

#### 4.2.2 Taxonomie für Prescriptive Analytics Use Cases

Die Detaillierung von Prescriptive Analytics Use Case Ideen muss zielgerichtet unterstützt werden (siehe Kapitel 2.4.1). Für diesen Schritt wird die **Prescriptive Analytics Use Case Taxonomie** bereitgestellt. Sie dient der initialen Charakterisierung und Verfeinerung einer Prescriptive Analytics Use Case Idee. Die Taxonomie wurde auf der *CIRP CMS* als [WNG+25] vorveröffentlicht. Die Entwicklung basiert auf der Forschungsmethode nach NICKERSON ET AL. [NVM13]. Die Taxonomie baut in Teilen auf den Ansätzen aus Kapitel 3.3.2 auf. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen. Die Taxonomie für Prescriptive Analytics Use Cases ist in Bild 4-4 dargestellt.

Problemstellung	Ziel KPI	Verfügbarkeit			Qualität			Leistung		
	Problemhäufigkeit	Wiederkehrend			Einmalig			Fortlaufend		
	Echtzeitfähigkeit	Direkte Auswirkungen			Langzeitauswirkungen			Vernachlässigbare Auswirkungen		
	Art des Auslösers	Anomaliedetektion			Menschliche Interventionen			Zustandsinformation (ereignisbasierter Auslöser)		
Geschäftsfelder	Domäne	Ressourcen		Produkt		Überwachender Prozess		Betrieb		Umfeld
	Auswirkungsbereich	Fabrik	Produktions-einheit	Produktions-linie	Produktions-zelle	untergeordnete Einheit der Zelle		Wertschöpfungs-netzwerk		
Entscheidungstyp	Entscheidungsstrategie	Konkurrierend				Einzel				
	Ansatz der Entscheidung	Reaktiv				Proaktiv				
Input	Datenquelle	Standort-daten	Produkt-daten	Wartungs-daten	Operative Daten	Objekt-daten	Kunden-daten	Daten zur Lieferkette	Qualitäts-daten	Material-flussdaten
	Umgebung	Deskriptive Daten		Diagnostische Daten		Prädiktive Daten		Präskriptive Daten		
Output	Mensch-Algorithmus-Interaktion	Decision Support			Decision Augmentation			Decision Automation		

Bild 4-4: Taxonomie für Prescriptive Analytics Use Cases

Die Taxonomie besteht aus den Oberkategorien Problemstellung, Geschäftsfelder, Entscheidungstyp, Input und Output. Jede Oberkategorie wird durch Subkategorien verfeinert. Die **Problemstellung** von Prescriptive Analytics Use Cases wird durch die **Ziel KPI**, **Problemhäufigkeit**, **Echtzeitfähigkeit** und **Art des Auslösers** definiert. Die Ziel

KPI beschreibt, welchen Zweck der Use Case in der Produktion verfolgt. Mit der Problemhäufigkeit wird der Auslöser der Präskription entlang einer Zeitachse definiert. Die benötigte Reaktionsgeschwindigkeit nach der Präskription wird durch die Echtzeitfähigkeit beschrieben. Die Art des Auslösers definiert, wodurch der Use Case angesteuert wird. Das **Geschäftsfeld** von Prescriptive Analytics Use Cases wird durch die **Domäne** und den **Auswirkungsbereich** beschrieben. Die Domäne charakterisiert den Teil in der Produktion, welcher die Präskription auslöst. Der Auswirkungsbereich beschreibt, wie weitreichend die Folgen einer Handlungsempfehlung sind. Mithilfe der Subkategorien **Entscheidungsstrategie** und **Ansatz der Entscheidung** wird der **Entscheidungstyp** festgelegt. Die Entscheidungsstrategie beschreibt, ob andere Entscheidungsunterstützungssysteme berücksichtigt werden müssen. Der Ansatz der Entscheidung legt fest, ob proaktiv oder reaktiv agiert wird. **Input** und **Output** werden über die **Datenquelle**, **Umgebung** und **Mensch-Algorithmus-Interaktion** beschrieben. Die Datenquelle definiert, welche Daten für die Präskription berücksichtigt werden. Die Umgebung definiert, welcher Art diese Daten sind. Die Mensch-Algorithmus-Interaktion orientiert sich an den Stufen der hybriden Entscheidungsfindung (siehe Kapitel 2.4.2).

Je Subkategorie ist keine Mehrfachauswahl bei der Einteilung von Use Cases im Rahmen der Taxonomie möglich. Alle einzelnen Elemente der Subkategorien werden in Anhang A2.3 erläutert. So entsteht eine eindeutige Charakterisierung von Use Cases. Diese kann in Zukunft genutzt werden, um bei einer ausreichenden Ähnlichkeit von Use Cases mögliche Lösungsmuster zu empfehlen (vgl. [DAG13, S. 119]). Das vorgeschlagene Prinzip ist in Anhang A2.4 für den Kontext von Prescriptive Analytics Use Cases in der Produktion kurz zusammengefasst.

### 4.2.3 Design Prinzipien für Prescriptive Analytics Use Cases

Wie in der Problemanalyse herausgearbeitet (siehe Kapitel 2.4.1), gibt es viele bleibende Herausforderungen bei der konkreten Ausgestaltung von Prescriptive Analytics Use Cases. Um diese adäquat zu adressieren, werden **Design Prinzipien für Prescriptive Analytics Use Cases** bereitgestellt. Sie unterstützen bei der konkreten Umsetzung der Use Cases. Die Design Prinzipien wurden auf der *CIRP Design* als [WME+24] veröffentlicht. Die Entwicklung der Design Prinzipien basiert auf der Forschungsmethode nach MÖLLER ET AL. [MGO20]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die Design Prinzipien dienen als kontinuierliche Leitlinien beim Treffen von Designentscheidungen bei der Entwicklung von Prescriptive Analytics Use Cases. Ein Überblick zu den Design Prinzipien ist in Tabelle 4-1 dargestellt.

Tabelle 4-1: Design Prinzipien (DP) für Prescriptive Analytics Use Cases

Design Prinzip	Erläuterung
<b>DP1: Datenerfassung und Modellbildung</b>	Verwendung von Metriken, die auf den Prinzipien der Bounded Rationality (siehe Anhang A1.2) beruhen
<b>DP2: Aufwandsreduzierung bei der Umsetzung</b>	Bereits formalisiertes Expertenwissen im Unternehmen nutzen
<b>DP3: Mensch-Algorithmus-Interaktion</b>	Anpassen des Use Case Automatisierungsgrades
<b>DP4: Industrie 4.0 Capability und Kompatibilität</b>	Sicherstellung der nahtlosen Integration in bestehende Analytics Optimierungsinitiativen
<b>DP5: Analytics Insights nutzen</b>	Fokus auf Actionable Decisions
<b>DP6: Erfolgsfaktoren für die Umsetzung</b>	Entscheidungskonnektivität fördern und Silo-Installationen vermeiden

Neben der Berücksichtigung der benötigten Optimalität bei der **Datenerfassung und Modellbildung** (DP1) ist es essenziell im Anwendungsfall auch die zugrundeliegenden Dokumente im Unternehmen einfließen zu lassen. Dies kann zu einer **Aufwandreduzierung bei der Umsetzung** (DP2) führen. Die Mensch-Algorithmus Interaktion (DP3) ist Use Case spezifisch zu wählen. Das DP4 (**Industrie 4.0 Capability und Kompatibilität**) ergänzt die Empfehlung, neue Use Cases frühzeitig in bestehende Optimierungsinitiativen im Unternehmen einzufassen. Weiterhin generieren Prescriptive Analytics Use Cases nur nutzbare **Analytics Insights** (DP5), wenn bei deren Konzeption auch die eigentlichen, geplanten Aktionen berücksichtigt werden. **Erfolgsfaktoren für die Umsetzung** (DP6) sind unter anderem das Vermeiden von Silo-Installationen und das Verbinden von Use Cases zur Entscheidungsunterstützung. Eine detaillierte Erläuterung der Design Prinzipien wird in Anhang A2.2 bereitgestellt.

### 4.3 Vorgehensmodell

Das **Vorgehensmodell** der Ausarbeitung stellt die sachlogische Abfolge der Aktivitäten dar. Mögliche Iterationen sind vorgesehen, aber nicht visualisiert. Es wird mithilfe des Ansatzes des Method Engineerings nach BRINKKEMPER hergeleitet [Bri96]. Zugrunde liegt eine Kombination existierender etablierter Vorgehensmodelle (siehe Anhang A3.1). Basierend auf diesen wird wiederum ein für den vorliegenden Sonderfall synthetisiertes Vorgehensmodell abgeleitet.

In **Kapitel 4.3.1** wird das übergeordnete Vorgehensmodell im Überblick beschrieben. **Kapitel 4.3.2** ordnet das Vorgehensmodell in existierende Referenzprozesse ein. In **Kapitel 4.3.3** wird aufbauend auf den beiden vorherigen Kapiteln das Vorgehensmodell sowie die Verknüpfung der Artefakte zur Unterstützung vorgestellt.

### 4.3.1 Das Vorgehensmodell im Überblick

Im Folgenden wird das **Vorgehensmodell im Überblick** dargestellt und eingeordnet. Eine Diskussion für eine Instanziierung des Vorgehensmodells für kleine und mittelständische Unternehmen sowie die Implikationen einer solchen Anwendung in Form eines Permutationskonzepts wird in Kapitel 5.3.3 behandelt. Eine Anwendung in kleineren Unternehmen ist aber nicht direkt ausgeschlossen. **Kernanwender** werden je Phase spezifiziert, entsprechen aber den übergeordneten Rollen aus Kapitel 2.3.4. Um eine effektive Anwendung des Vorgehens zu ermöglichen, ist der Grad der gegebenen Unterstützung von hoher Relevanz. Eine Überregulierung des Vorgehens ist zu vermeiden. Diese kann zur Verlangsamung in Entscheidungsprozessen bis hin zum Stillstand führen [Moc21, S. 178]. Für das grundlegende Verständnis der Einbettung der Inhalte in den Unternehmenskontext wurde in der Problemanalyse auf die dynamische Prozessperspektive der Entwicklung von Prescriptive Analytics Use Cases (siehe Kapitel 2.5.1) eingegangen. Ergänzend dazu wird in Bild 4-5 der Blick auf die **statische Sicht** der Use Case Entwicklung dargestellt.

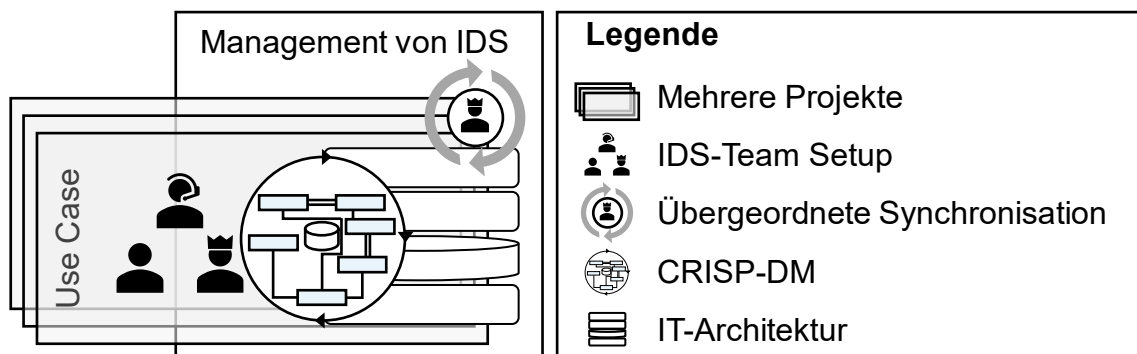


Bild 4-5: *Management von IDS in der Produktion aufbauend auf [EWB+24]*

Die statische Sicht auf das **Management von IDS** gibt einen Überblick über die relevanten Aspekte bei der Entwicklung von Analytics **Use Cases** in der Produktion. Die Herausforderung im Management von IDS liegt primär in der **Synchronisation** verschiedener **Projekte** bei gleichzeitiger lokaler Optimierung der einzelnen Lösungen. Weiterhin sorgt die Interdisziplinarität des Themas dafür, dass **Team Setup**, **IT-Architektur** und projektbezogene Herausforderungen in den einzelnen **CRISP-DM Zyklen** berücksichtigt werden müssen [EWB+24]. Eine detaillierte Darstellung mit erweiterten Erklärungen je Element kann dem Anhang entnommen werden (siehe Anhang A2.1).

Das resultierende Vorgehensmodell zur Unterstützung der Prescriptive Analytics Use Case Entwicklung gliedert sich in vier übergeordnete Schritte, welche in den folgenden Kapiteln im Detail erläutert werden (vgl. Bild 4-6). Das übergeordnete Vorgehensmodell strukturiert die Planung, Konzeption und Integration von mehreren Prescriptive Analytics Use Cases in der Produktion. Zum Zwecke der Vernetzung und Ganzheitlichkeit des Ansatzes wird nicht ein einzelner Use Case, sondern eine sinnvolle Grundgesamtheit an Use Cases für das betroffene System unter Observation konzeptioniert.

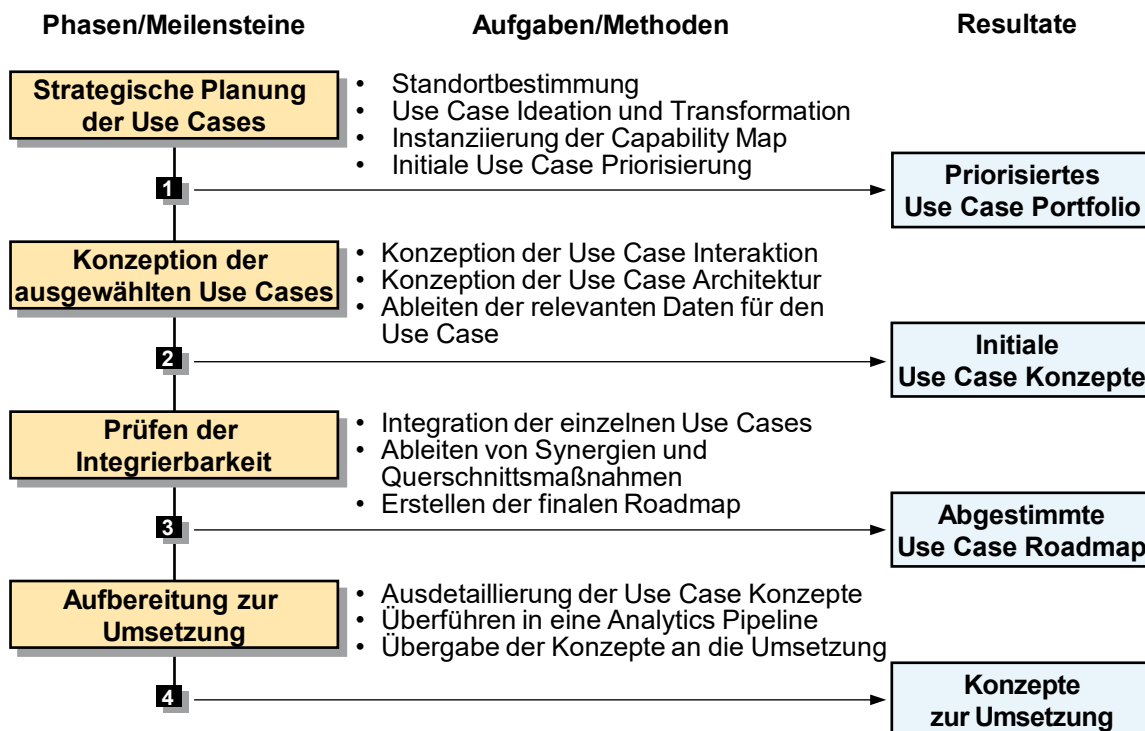


Bild 4-6: Übergeordnetes Vorgehensmodell der Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion (Use Case bezieht sich immer auf Prescriptive Analytics Use Case)

Die übergeordnete Struktur des Vorgehens ist in Anlehnung an ein Plan-Do-Check-Act Vorgehen (PDCA-Zyklus) entworfen. Im Unterschied zu einem klassischen PDCA-Zyklus wird in der Do-Phase lediglich ein Konzept erarbeitet und nicht die Umsetzung angestrebt (vgl. [MN09, S. 1]). Das Ergebnis der ersten Phase (**strategische Planung der Use Cases**) ist ein **priorisiertes Use Case Portfolio**. Darauf aufbauend wird die **Konzeption der ausgewählten Use Cases** durchgeführt. Mithilfe der **initialen Use Case Konzepte** wird das **Prüfen der Integrierbarkeit** angestoßen. Dabei wird eine **abgestimmte Use Case Roadmap** erarbeitet. Darauf aufbauend werden die ausgewählten Use Cases in der **Aufbereitung zur Umsetzung** final detailliert. **Konzepte zur Umsetzung** resultieren.

### 4.3.2 Einordnung des Vorgehensmodells

Das vorgestellte Vorgehensmodell adressiert die sachlogische Reihenfolge bei der Bearbeitung. Wie in der Problemanalyse (siehe Kapitel 2.5.6) betont, werden Data Science Projekte jedoch oft iterativ bearbeitet und Stück für Stück implementiert und skaliert (vgl. [HBK+24]). Zur **Einordnung des Vorgehensmodells** in die existierenden Prozesse und Strukturen in Unternehmen muss neben möglichen Iterationen auch der zeitliche Aspekt berücksichtigt werden. Dafür wird in Bild 4-7 eine Einbettung in zeitliche und organisatorische Randbedingungen für eine effiziente Integration in einen Unternehmenskontext vorgenommen (siehe [HBK+24, S. 4, WWS+24]).

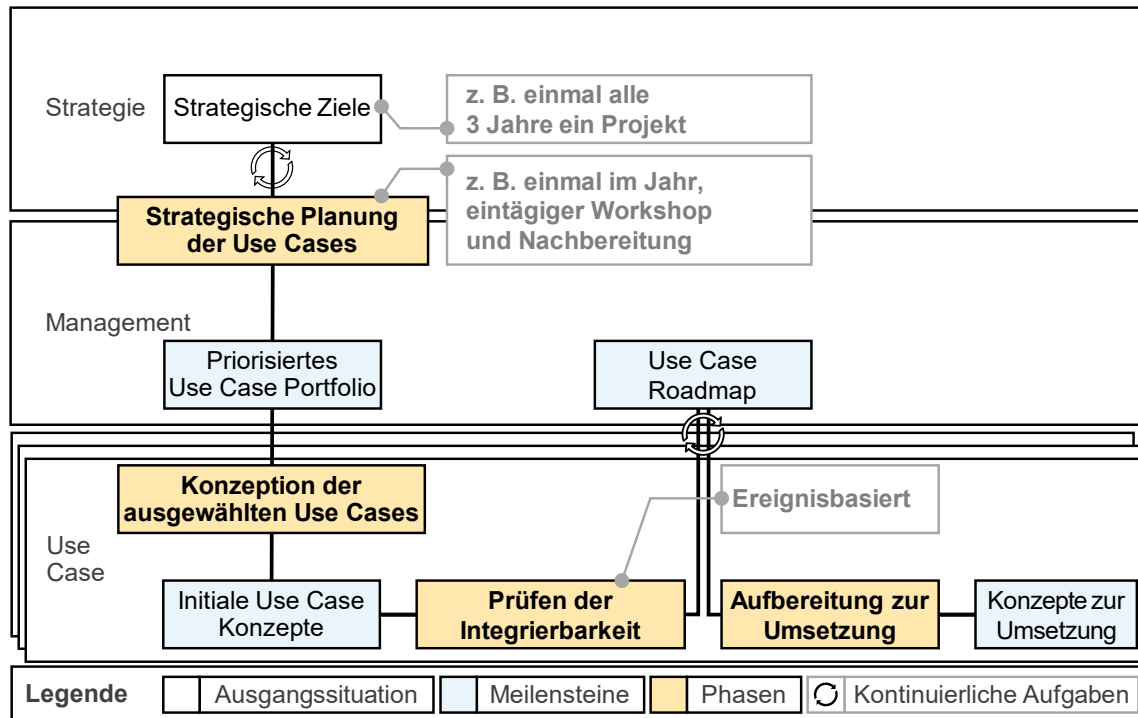


Bild 4-7: Einordnung des Vorgehens in übergeordneten Ebenen auf [Lip21, Moc21, S. 163, GKD23]

Aus dem Vorgehen resultieren drei **übergeordnete Perspektiven** zur Entwicklung von Prescriptive Analytics Lösungen in der Produktion. Diese müssen vor der finalen Umsetzung **geplant, konzeptioniert** und auf die **Integrierbarkeit geprüft** werden (siehe Kapitel 2.5.1). Eingerahmt werden diese Phasen durch die strategische Ebene (höhere Abstraktion) und die konkreten Implementierungsprojekte (konkretere Realisierungsebene). Oftmals gibt es bereits existierende Roadmaps aus Digitalisierungsstrategien (vgl. [Lip21]) oder Programmen mit KI-Fokus (vgl. [GKD23, HMK23]), die berücksichtigt werden müssen. Die Übergabe der Inhalte im einzelnen Use Case wird in der Regel durch Projekte mit iterativem Ansatz aufgegriffen, zum Beispiel nach dem CRISP-DM Vorgehensmodell (siehe Kapitel 2.5.6). Insbesondere eine erste Machbarkeitsstudie von Teillösungen kann bereits während der Phase vier parallel angegangen werden.

### 4.3.3 Das Vorgehensmodell im Detail

Die Schritte aus dem **Vorgehensmodell** werden mit entsprechenden Artefakten unterstützt (vgl. Bild 4-8). Die Artefakte aus dem Strukturierungsrahmen der Dissertation werden nicht eingeordnet, sondern stehen durchgehend als Referenz zur Verfügung. Die Artefakte dienen dem Befüllen der relevanten Partialmodelle des Modellierungskonzeptes.

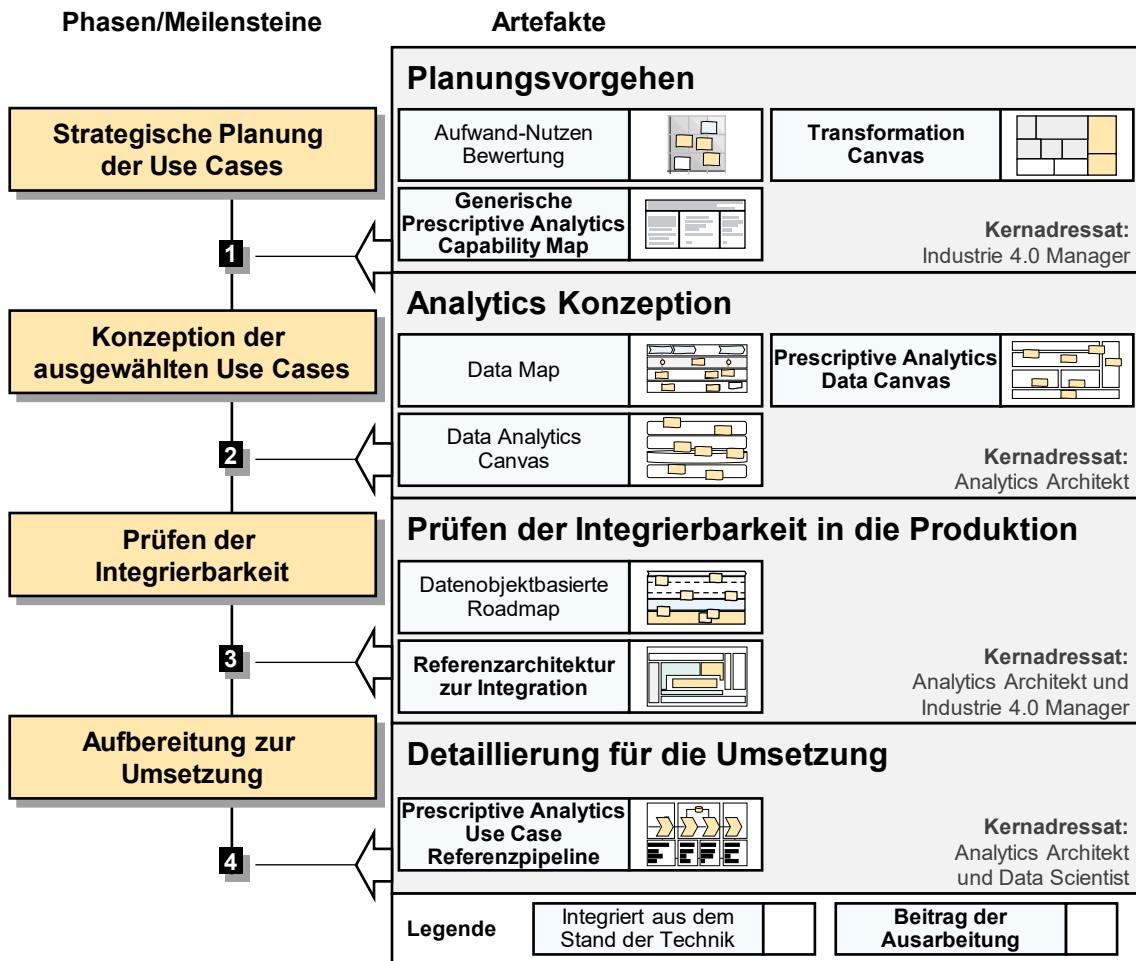


Bild 4-8: Verortung der Artefakte in dem übergeordneten Vorgehensmodell

Je Phase werden in den folgenden Unterkapiteln **Kernadressat**, einzelne **Schritte**, relevante **Artefakte**, **Partialmodelle** und die **Kernergebnisse** für das **Vorgehensmodell im Detail** beschrieben. Im Rahmen der Ausarbeitung werden die Begriffe **Artefakt** (Definition siehe Kapitel 1.3) und **Partialmodell** (siehe Definition Kapitel 2.1.1) verwendet. Die folgende Konvention wird zur Unterscheidung der beiden Begriffe verwendet. Ein Artefakt wird genutzt um Struktur, Aussehen oder generische Inhalte für ein Partialmodell vorzugeben. Ein Artefakt dient als Unterstützung beim Befüllen eines Partialmodells.

Die Auswahl der Kernadressaten baut auf Kapitel 2.3.4 auf. Als Kernadressaten werden der **Industrie 4.0 Manager**, **Analytics Architekt** und **Data Scientist** den jeweiligen Phasen zugeordnet. Eine ausführliche Herleitung ist Anhang A3.1 zu entnehmen. In allen Phasen des Vorgehens wird das Modellierungskonzept (zusammenhängende Partialmodelle) durchgehend als Medium zur Strukturierung, Erarbeitung, Kommunikation und Dokumentation der Teilergebnisse genutzt. Über die reine Konzeption hinaus müssen Data Science Vorhaben auch gemanagt werden [HBK+24, S. 4]. Dafür werden im Folgenden etablierte Ansätze aus dem Projektmanagement an geeigneter Stelle integriert.

#### 4.3.3.1 Phase eins: Strategische Planung der Use Cases

**Kernadressat** der **Phase eins** ist der Industrie 4.0 Manager. Übergeordnetes Ziel der Phase ist die Erfassung des Ist-Standes des System under Observation und die Sammlung einer ersten Menge an vielversprechenden Prescriptive Analytics Use Cases. Eine Auswahl dieser soll anschließend konzeptioniert werden. Als Eingangsgröße werden strategische Ziele für den Bereich aufgenommen. Die Phase der strategischen Planung der Prescriptive Analytics Use Cases beginnt mit einer **Standortbestimmung**. Dafür werden relevante Vorarbeiten zusammengetragen. Unter Vorarbeiten sind alle vorhandenen Analytics Use Cases im Betrachtungsraum sowie deren Beschreibung zu verstehen. Falls vorhanden, werden existierende Dokumentationen von Unternehmensprozessen, Applikationsarchitekturen, Datenarchitekturen und technischen Architekturen zusammengetragen.

Basierend auf dem Ist-Stand werden vielversprechende, aber bisher nicht präskriptive, Use Cases in Ideen für Prescriptive Analytics Use Cases transformiert. Dies geschieht in der **Use Case Ideation und Transformation**. Dafür wird die Prescriptive Analytics Use Case Transformation Canvas eingesetzt. Es resultiert eine Menge an realisierbaren Prescriptive Analytics Use Cases. Für eine Abschätzung des Aufwandes werden die für Prescriptive Analytics relevanten Capabilities des Unternehmens bewertet. Zur Bewertung wird die generische Prescriptive Analytics Capability Map eingesetzt und für das Unternehmen instanziiert. Die Abschätzung erfolgt im Schritt der **Instanziierung der Capability Map** basierend auf einer Experteneinschätzung und wird in folgenden Schritten weiter verfeinert. Für eine initiale Abschätzung des Nutzens wird neben den strategischen Zielen die Expertenmeinung des Analytics Architekten und Data Scientists herangezogen. Mithilfe der Ideen für Prescriptive Analytics Use Cases wird eine **initiale Use Case Priorisierung** vorgenommen. Die Priorisierung basiert auf einer ersten groben Aufwand-Nutzen-Abschätzung zusammen mit einem Analytics Architekten und den fachlichen Verantwortlichen. Folgende Artefakte sind somit für die Realisierung der Phase relevant:

- Prescriptive Analytics Use Case Transformation Canvas (siehe Kapitel 4.5.2)
- Generische Prescriptive Analytics Capability Map (siehe Kapitel 4.5.3)
- Aufwand-Nutzen-Bewertung (siehe Anhang A4.3)

Ferner werden folgende **Partialmodelle** (siehe Kapitel 4.4.3) mithilfe der Artefakte gefüllt: Use Case Portfolio und Capability Map. Wenn Vorarbeiten vorhanden sind, werden Prozessmodell, Applikationsarchitektur, Datenkatalog und technische Architektur in der Produktion mit dem vorhandenen Vorwissen gefüllt. Das **Kernergebnis der Phase** ist ein initial **priorisiertes Use Case Portfolio**. Dieses dient als Empfehlung, welche bereits implementierten Use Cases zu Prescriptive Analytics Use Cases erweitert oder welche komplett neu konzipiert werden sollen.

#### 4.3.3.2 Phase zwei: Konzeption der ausgewählten Use Cases

Der Analytics Architekt stellt den **Kernadressat** der **Phase zwei** dar. Übergeordnetes Ziel ist die Konzeption der ausgewählten Prescriptive Analytics Use Cases. Dafür ist ein initiales Verständnis des Betrachtungsraums essenziell [HBK+24]. Dies beinhaltet die Erarbeitung von Konzepten, wie mit dem Use Case interagiert wird, welche Applikationsarchitektur dafür notwendig ist und welche Daten im Use Case von Bedeutung sind. Falls aus der Standortbestimmung in Phase eins keine Informationen über die Prozess-, Applikations-, Daten- oder technische Architektur vorliegen, gilt es diese zuerst zusammenzustellen und zu modellieren. Dafür sind die einzelnen Partialmodelle mit den jeweiligen Experten iterativ zu befüllen (Prozess-, Daten-, Applikations- und technische Architektur). Dieser Schritt ist einmalig durchzuführen. Die Ergebnisse können bei weiteren Durchläufen des Vorgehensmodells als Vorarbeiten aufgegriffen werden. Für die Erfassung der Prozessarchitektur wird die Data Map verwendet.

Basierend darauf können die Use Case Konzepte detailliert werden. Die Überführung einer Use Case Idee hin zu einem Lösungskonzept wird von mehreren Artefakten unterstützt. Zuerst wird die Use Case Interaktion definiert. Zur **Konzeption der Use Case Interaktion** werden die relevanten Entscheidungsträger, die zu unterstützenden Entscheidungen und die damit verbundenen Prozesse definiert. Für die Konzeption der Use Case Interaktion werden die späteren Nutzer hinzugezogen. Basierend auf dieser kann mithilfe der Analytics Canvas ein Grobkonzept für die Use Case Applikationsarchitektur entwickelt werden. Das Grobkonzept der **Konzeption der Use Case Architektur** gibt einen Überblick über die Zusammenhänge von Datenquellen, Datenspeicherorten, Analytics Capabilities und übergeordneten Use Cases. Mithilfe der Architektur und der Prescriptive Analytics Data Canvas werden die benötigten Daten für den Use Case gesammelt. Die Canvas gibt für das **Ableiten der relevanten Daten** eine initiale Struktur zur Sammlung relevanter Datenobjekte vor. Folgende Artefakte sind somit für die Realisierung der Phase relevant:

- Data Map (siehe Kapitel 3.2.3)
- Analytics Canvas (siehe Kapitel 3.2.2)
- Prescriptive Analytics Data Canvas (siehe Kapitel 4.5.4)

Die wichtigsten verwendeten Partialmodelle (siehe Kapitel 4.4.3) sind die Use Case Interaktion, Use Case Architektur und Use Case Daten. Eine zur Spezifikation begleitende prototypische Implementierung kann insbesondere in neuen Umgebungen oder besonders technisch anspruchsvollen Use Cases bei der kontinuierlichen Erarbeitung unterstützen [SvS+24, S. 173]. Diese ist nicht zwingend nötig, trägt aber als Erfolgsfaktor zum Gelingen des Gesamtvorhabens bei [HBK+24, S. 4, EWB+24, HJB21, S. 202]. Die prototypische Implementierung kann hier die Einschätzung der Machbarkeit und der genaueren Definition der benötigten Daten verbessern. Das **Kernergebnis** der Phase sind Prescriptive Analytics **Use Case Konzepte** für die ausgewählten Use Cases.

#### 4.3.3.3 Phase drei: Prüfen der Integrierbarkeit

**Kernadressaten** der **Phase drei** sind der Industrie 4.0 Manager und der Analytics Architekt. Übergeordnetes Ziel ist die Ermittlung von Synergiepotenzialen und möglichen Schnittstellen zwischen den einzelnen erarbeiteten Prescriptive Analytics Use Case Konzepten. Hinzugezogen werden weiterhin etwaige bereits modellierte und implementierte Use Cases. Wichtig ist es, Data Science und IT-Experten einzubinden, um die Skalierbarkeit der vorliegenden Use Cases bewerten zu können [SvS+24, S. 180]. Zur Kommunikation der Zwischenergebnisse im Dialog mit den Experten wird auf die Partialmodelle zurückgegriffen.

Zuerst wird die **Integration** der Use Cases in die Prozess-, Applikations-, Daten- und technische Architektur **geprüft**. Dafür werden die Partialmodelle zur Integration verwendet. Aufbauend auf den einzelnen Konzepten und der Integrationsicht werden Aussagen zu möglichen Synergien und Querschnittsmaßnahmen abgeleitet. Dafür wird eine Sammlung typischer Analysefragen bereitgestellt. Eine anschließende Überprüfung der initial vorgenommenen Bewertung der Capabilities aus Phase eins (siehe Kapitel 4.5.2) wird durchgeführt. Basierend auf den Erkenntnissen zu Synergie- und Schnittstellenpotenzialen wird eine finale Roadmap zur Implementierung abgeleitet. Sollten Use Cases als ungeeignet bewertet werden, kann die Menge an Use Cases reduziert oder ein weiterer Use Case aus dem Portfolio ausgewählt und spezifiziert werden. Im Fokus des **Erstellens der finalen Roadmap** stehen datenobjektbezogene Synergien. Dies beruht auf der Aussage, dass die größten Aufwände in Data Science Projekten auf die Datenakquise entfallen [EWB+24, HHS24, S. 56, HWS+19, S. 406]. Der initiale und rein qualitative Ansatz kann durch Methoden der Kostenrechnung unterstützt werden (vgl. [JLT+19, Jop21]). Folgende Artefakte sind somit für die Realisierung der Phase relevant:

- Referenzarchitektur zur Integration von Prescriptive Analytics (siehe Kapitel 4.5.5)
- Datenobjektbasierte Roadmap (siehe Anhang A4.8)

Ein für die Phase besonders relevantes Partialmodell ist die Roadmap. Alle Partialmodelle zur Integration und Konzeption sowie die Capability Map werden in der Phase drei zum Prüfen der Integrierbarkeit verwendet. **Kernergebnis** der dritten Phase ist eine **abgestimmte Use Case Roadmap**. Diese definiert die Festlegung auf die finale Menge an Prescriptive Analytics Use Cases zur Umsetzung.

#### 4.3.3.4 Phase vier: Aufbereitung zur Umsetzung

Die **Phase vier** adressiert neben dem Analytics Architekten die Zusammenarbeit mit dem Data Scientist (**Kernadressat**). Das übergeordnete Ziel der Phase ist die Bereitstellung von Konzepten mit einem Detaillierungsgrad, welcher für den Beginn eines Umsetzungsprojektes ausreichend ist.

Die initial erzeugten Use Case Konzepte aus Phase zwei werden nun für die Umsetzung durch den Data Scientist ausdetailliert. Hierbei steht die Konzeption einer möglichst dem Zweck angepassten („einfachen“) Prescriptive Analytics Pipeline im Vordergrund. Dafür werden alle Partialmodelle betrachtet und basierend auf den neuen Erkenntnissen ergänzt und detailliert. Dies beinhaltet, basierend auf den Vorarbeiten der Phase zwei, die Erstellung einer ersten Prescriptive Analytics Pipeline. Dazu wird die Prescriptive Analytics Referenzpipeline hinzugezogen. Die Referenzpipeline definiert in abstrahierter Form die benötigten Schritte bei der Umsetzung. Die Referenzarchitektur definiert, wie Prescriptive Analytics Use Cases in die existierende Architektur integriert werden. Die Konzepte zu den Use Cases sowie deren Integration in das Unternehmen werden durch den Analytics Architekten und Data Scientist weiter ausdetailliert. Final werden die Konzepte zur Übergabe an die Umsetzung aufbereitet. Die Design Prinzipien aus dem Strukturierungsrahmen können hinzugezogen werden. Folgende Artefakte sind somit für die Realisierung der Phase relevant:

- Prescriptive Analytics Use Case Referenzpipeline (siehe Kapitel 4.5.6)
- Referenzarchitektur zur Integration von Prescriptive Analytics (siehe Kapitel 4.5.5)

Ein besonders relevantes Partialmodell ist die Prescriptive Analytics Pipeline. Alle relevanten Partialmodelle zur Konzeption und Integration werden noch einmal verfeinert. **Detaillierte Konzepte zur Umsetzung** bilden das **Kernergebnis** der vierten Phase. Dies umfasst alle Partialmodelle und die Dokumentation der Entstehungsgeschichte dieser (getroffene Designentscheidungen). Die Konzepte werden zur Umsetzung weiterverwendet.

#### 4.4 Modellierungskonzept

EAM-Modelle werden oftmals als Schnittstelle zwischen domänenspezifischen Perspektiven und Modellen genutzt (siehe Kapitel 2.5.4). Dies bietet sich auch für die Einordnung der Ergebnisse des übergeordneten Vorgehensmodells an. Weiterhin kann EAM als Befähiger für die Konzeption übertragbarer KI und Analytics Use Cases genutzt werden [CWK23, S. 1]. Zur Anpassung von Aspekten aus dem EAM für die Konzeption von Prescriptive Analytics Use Cases wird im Folgenden ein geeignetes **Modellierungskonzept** vorgeschlagen.

Zuerst wird die übergeordnete Struktur des Modellierungskonzepts in **Kapitel 4.4.1** vorgestellt. Aufbauend auf der Struktur werden die relevanten Perspektiven für das Modellierungskonzept in **Kapitel 4.4.2** hergeleitet. Die dazugehörigen Partialmodelle werden in **Kapitel 4.4.3** erläutert und das dahinterliegende Metamodell in **Kapitel 4.4.4** abgeleitet. In **Kapitel 4.4.5** werden die Partialmodelle mit dem Metamodell verknüpft. Die Partialmodelle werden in **Kapitel 4.4.6** zum übergeordneten Vorgehen in Relation gesetzt.

#### 4.4.1 Einordnung des Modellierungskonzepts

Zur wissenschaftlichen Erarbeitung und **Einordnung des Modellierungskonzepts** im übergeordneten Vorgehensmodell werden die folgenden Schritte durchlaufen (vgl. Bild 4-9). Eine kompakte Darstellung und ergänzende Informationen zur wissenschaftlichen Erarbeitung können dem Anhang entnommen werden (siehe Anhang A3.2).




Bild 4-9: Zusammenhang des Modellierungskonzepts aufbauend auf [IEC42010, Hei24, Sch18]

Das Forschungsvorgehen orientiert sich an den Konventionen der ISO/IEC/IEEE 42010:2022 [IEC42010]. Aus dem **übergeordneten Vorgehen** der Spezifikationstechnik werden Informationsbedarfe (siehe Kapitel 2.5) abgeleitet. Den Informationsbedarfen werden die Rollen aus Kapitel 2.3.4 zugeordnet. Die **Aktivitäten** der **Rollen** werden mit spezifischen **Herausforderungen** und **Bedarfen** bei der Durchführung ergänzt (siehe Kapitel 2.4). Zur Begegnung der Herausforderungen und Aktivitäten werden **Perspektiven** auf das betrachtete System bereitgestellt. Dabei bündeln die Perspektiven die Bedarfe der Rollen und fassen diese zusammen. Ergänzend dazu werden **Partialmodelle** eingeführt, welche der Erfüllung der Bedarfe der verschiedenen Perspektiven dienen. Sie werden gebündelt und strukturiert zur Verfügung gestellt. Partialmodelle bilden verschiedene Perspektiven aus einem Modell eines **spezifischen Systems** ab.

Im Kontext der Ausarbeitung wird eine Trennung zwischen Partialmodellen und Gesamtmodell vorgenommen. Die Partialmodelle werden einzeln aufgebaut und sind durch die Wiederverwendung von Modellierungselementen miteinander vernetzt. Die Summe aller Partialmodelle und ergänzender modellierter Inhalte ergibt das Modell. Modellelemente bestehen aus Attributen. Sie werden charakterisiert durch Beziehungen. Dabei werden sie mit definierten Darstellungskonventionen abgebildet. Basierend auf den Partialmodellen kann ein **spezifisches Modell** in der Anwendung erzeugt werden.

Aufbauend auf dem **Zusammenhang des Modellierungskonzepts** (vgl. Bild 4-9) wird die Einordnung des folgenden Kapitels in der Spezifikationstechnik von links nach rechts in Bild 4-10 beschrieben.



#### 4.4.2 Zugrundeliegende Perspektiven

Die vier Phasen des übergeordneten Vorgehens müssen durch relevante Perspektiven unterstützt werden. Wie im Vorgehensmodell beschrieben, steht insbesondere die Unterstützung der Phasen Planung, Integration und Konzeption im Vordergrund. Ein Überblick über die den Phasen entsprechenden **zugrundeliegenden Perspektiven** ist in Bild 4-11 dargestellt. Sie aggregieren die benötigten Informationen zur Begegnung der Herausforderungen und Bedarfe der Aktivitäten im übergeordneten Vorgehensmodell. Die relevanten Perspektiven basieren auf den EAM-Dimensionen nach BITKOM und LANKHORST (vgl. Spalten in Bild 4-11) [BIT11, S. 13, Lan17, S. 44].





Perspektiven		Architekturdimensionen			
Strategie Management	Planung	Strategische Planung			
		Prozess- architektur	Applikations- architektur	Informations- architektur	Technische Architektur
Management IT/ Business	Integration				
Analytics Domäne	Konzeption				
					

Bild 4-11: Zugrundeliegende Perspektiven des Modellierungskonzepts auf die Architekturdomänen aufbauend auf Kapitel 2.5.5

Die zugrundeliegenden Perspektiven (**Planung, Integration und Konzeption**) bauen auf den Domänen **Management, Analytics, IT** und Produktion (**Domäne**) auf. Sie gestalten und verändern die **Prozess-, Applikations-, Informations- und technische Architektur** (vgl. Zeilen in Bild 4-11) in der Produktion. Die Berücksichtigung verschiedener Perspektiven induziert zusätzliche Komplexität in die modellbasierte Abbildung der Konzepte der Use Cases. Die Perspektiven werden aber benötigt, um die Integrierbarkeit, Konformität und Anwendbarkeit sicherzustellen. Auf diese Dimensionen wird zurückgegriffen, um eine Kompatibilität mit anderen Ansätzen mit Einfluss auf die Architektur eines Unternehmens sicherzustellen. Die Besonderheiten von Prescriptive Analytics Use Cases (siehe Kapitel 2.4) werden in den einzelnen Partialmodellen und in der Spezialisierung der Modellierung berücksichtigt. Das Aufbauen auf etablierten Perspektiven erhöht weiterhin die Akzeptanz bei der Einführung im Unternehmen. Ohne die Betrachtung der aufgeführten Architekturdimensionen werden isolierte Lösungen erzeugt. Die Gefahr besteht, dass nicht vernetzte Lösungen mit nicht wiederverwendbaren Datenprodukten erzeugt und in proprietären Werkzeugen und vereinzelt in Abteilungen verwaltet werden.

### 4.4.3 Partialmodelle

Die **Partialmodelle** ergeben sich aus den relevanten Informationsbedarfen und den zugrundeliegenden Perspektiven (detaillierte Herleitung siehe Anhang A2.5). Dabei ist die Modularisierung von Analytics Use Cases der primäre Hebel zur Professionalisierung von Industrial Data Analytics Aktivitäten. Durch diese wird eine Befähigung von Unternehmen mit Fokus auf die Freilegung von Skaleneffekten erzeugt [SWK+24, S. 65]. Die Freilegung von Skaleneffekten kann durch die Verwendung von modellbasierten Ansätzen systematisch angegangen werden. Im Rahmen der Ausarbeitung werden **elf Partialmodelle** zur Planung, Konzeption und Integration von Prescriptive Analytics Use Cases für die Produktion bereitgestellt. Die Partialmodelle haben zwei Hauptfunktionen:

- Sie dienen der **Unterstützung der Durchführung** der Phasen aus dem übergeordneten Vorgehensmodell (siehe Kapitel 4.3.1).
- Weiterhin beschränken die Partialmodelle die erlaubte Menge an Modellierungselementen und **geben eine Struktur vor**. Ein (Partial-)Modell dient dem Zweck, Fragen der relevanten Akteure zu beantworten [Lan17, S. 149].

Es resultiert ein Modellierungskonzept bestehend aus Perspektiven (Planung, Integration und Konzeption) sowie domänenspezifischen Partialmodellen. Ein Überblick über alle Partialmodelle des Modellierungskonzepts ist in Bild 4-12 visualisiert. Die Befüllung dieser Partialmodelle wird durch entsprechende Artefakte zur Unterstützung vereinfacht (vgl. Kapitel 4.5.1). Im Folgenden werden alle Partialmodelle kurz umrissen.

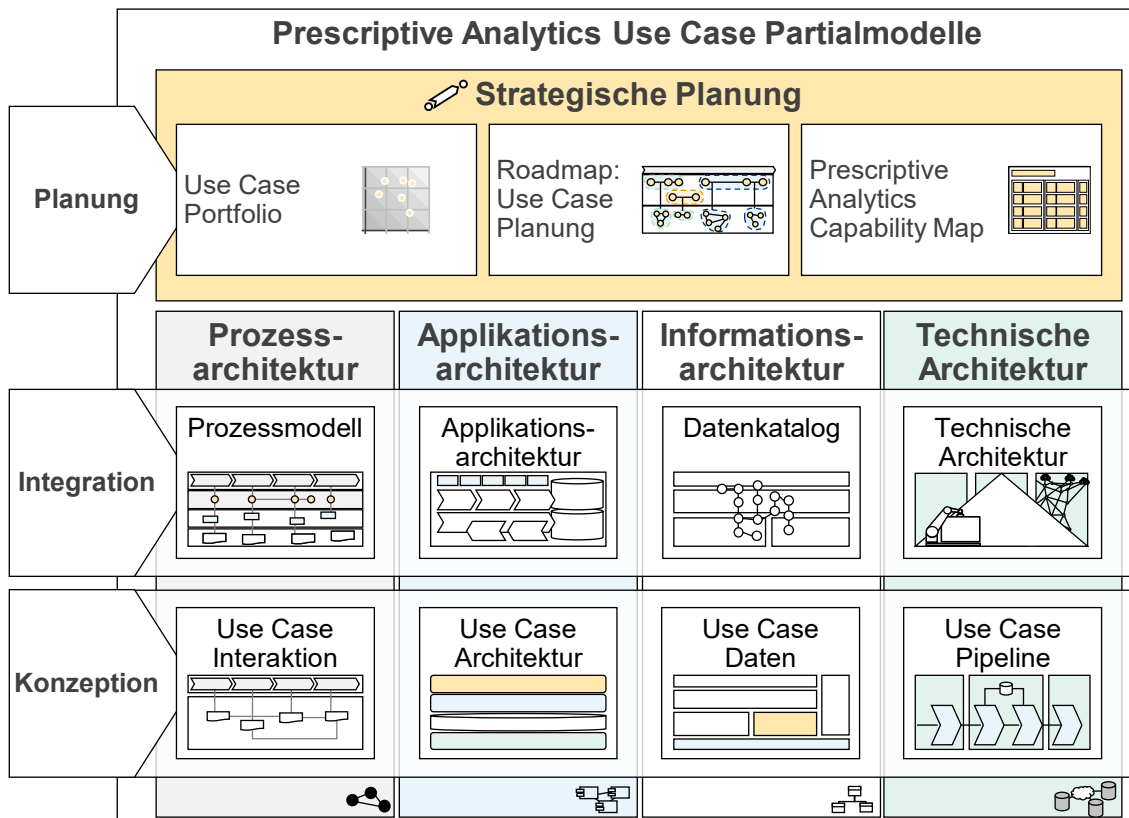


Bild 4-12: Überblick über die Partialmodelle der Spezifikationstechnik

### **Partialmodelle zur Planung** von Prescriptive Analytics Use Cases für die Produktion

- **Use Case Portfolio:** Das Portfolio hilft bei der Abwägung der Machbarkeit und des Nutzens der verschiedenen Use Cases. Mithilfe dieser beiden Kriterien kann das Portfolio als Schnittstelle zwischen der Managementdomäne und der Konzeption genutzt werden, um eine Menge an Use Cases zu verwalten.
- **Roadmap zur Use Case Planung:** Die Roadmap unterstützt bei der Überführung der geplanten Use Cases und der dazugehörigen Datenobjekte in eine sachlogische und zeitlich sinnvolle Reihenfolge. Das Aufdecken von Synergien steht im Vordergrund.
- **Prescriptive Analytics Capability Map:** Die Capability Map dient der übergeordneten Strukturierung. Sie beschreibt die Capabilities, die zur Entwicklung von Prescriptive Analytics Use Cases in der Organisation etabliert werden müssen.

### **Partialmodelle zur Integration** von Prescriptive Analytics Use Cases in die Produktion

- **Prozessmodell:** Das Prozessmodell lehnt sich an gängige Standards zur Prozessbeschreibung (hier: Data Map) an. Im Modell werden die Zusammenhänge von Geschäftsprozessen, Daten und Use Cases strukturiert aufgenommen.
- **Applikationsarchitektur:** Die Applikationsarchitektur dient der Strukturierung der für die Prescriptive Analytics benötigten Applikationen für den Betrieb, die Wartung und die generelle Orchestration verschiedener Use Cases.
- **Datenkatalog:** Der Datenkatalog setzt die im Unternehmen vorhandenen Datenobjekte in eine Beziehung und strukturiert diese für eine mögliche Wiederverwendung. Der Schwerpunkt liegt auf der Abbildung der ganzheitlichen Zusammenhänge der Daten im Unternehmen.
- **Technische Architektur der Produktion:** Die technische Architektur definiert wie die Prescriptive Analytics Use Cases untereinander harmonisieren und in die Produktion zu integrieren sind. Die Sicht baut direkt auf der Use Case Pipeline auf.

### **Partialmodelle zur Konzeption** von Prescriptive Analytics Use Cases für die Produktion

- **Use Case Interaktion:** Die Use Case Interaktion beschreibt die Kommunikation und den Informationsaustausch zwischen Nutzer und Lösung. Es werden die Schritte und Abläufe der Interaktion im Use Case detailliert beschrieben. Dies umfasst die Eingabe- und Ausgabedaten, die übermittelten Nachrichten und die Schnittstellen, die zur Kommunikation verwendet werden.
- **Use Case Architektur:** Dieses Partialmodell fokussiert sich auf die Use Case Architektur der spezifischen Umsetzung. Es steht die Verknüpfung und Aggregation aller relevanten Ressourcen, Daten, Datenbanken und daraus folgenden Use Cases im Vordergrund.
- **Use Case Daten:** Die Use Case Daten werden in Form von Ebenen strukturiert und in Beziehung gesetzt. Die Beziehungen zwischen den Daten dienen primär dazu, die benötigten Verknüpfungen aufzudecken.

- **Use Case Pipeline:** Die Use Case Pipeline beschreibt die Verarbeitungskette von den Rohdaten des Prescriptive Analytics Use Cases bis zur Handlungsempfehlung. Die Use Case Pipeline ermöglicht es, die verschiedenen Schritte und Aktivitäten systematisch zu organisieren und sicherzustellen, dass der Use Case effizient und effektiv umgesetzt wird.

Dem Anhang sind beispielhafte Partialmodelle in generischer Form zur Orientierung als Blueprints beigelegt (siehe Anhang A2.8).

#### 4.4.4 Spezialisierung des ArchiMate Metamodells

Wie in Kapitel 4.4.1 angeführt, wird das Modellierungskonzept an die Grundprinzipien des EAM angelehnt. Es wird auf einem etablierten Metamodell aufgesetzt, um eine Konformität mit anderen Ansätzen und Standards zu gewährleisten. Existierende Metamodelle werden oftmals noch einmal unternehmensspezifisch instanziiert [Stu18, S. 27]. Im Bereich des EAM gibt es über 50 verschiedene Ansätze mit meist eigenem Metamodell [Mat11]. Ein etabliertes Metamodell (Quasistandard) im Bereich des EAM ist *ArchiMate* [Lan17, Ope24-ol, GAM24, S. 14]. Das im Folgenden dargelegte Konzept der **Spezialisierung des ArchiMate Metamodells** kann gleichsam auf andere Quasistandards für einen unternehmensspezifischen Einsatz übertragen werden (z. B. Metamodell aus LeanIX<sup>13</sup>). Die Verwendung von *ArchiMate* wird unter anderem von LICK ET AL. für den Entwurf von produktionsnahen KI Use Cases empfohlen [LWK23, S. 111]. Die resultierende Spezialisierung ist vereinfacht in Bild 4-13 zusammengefasst.

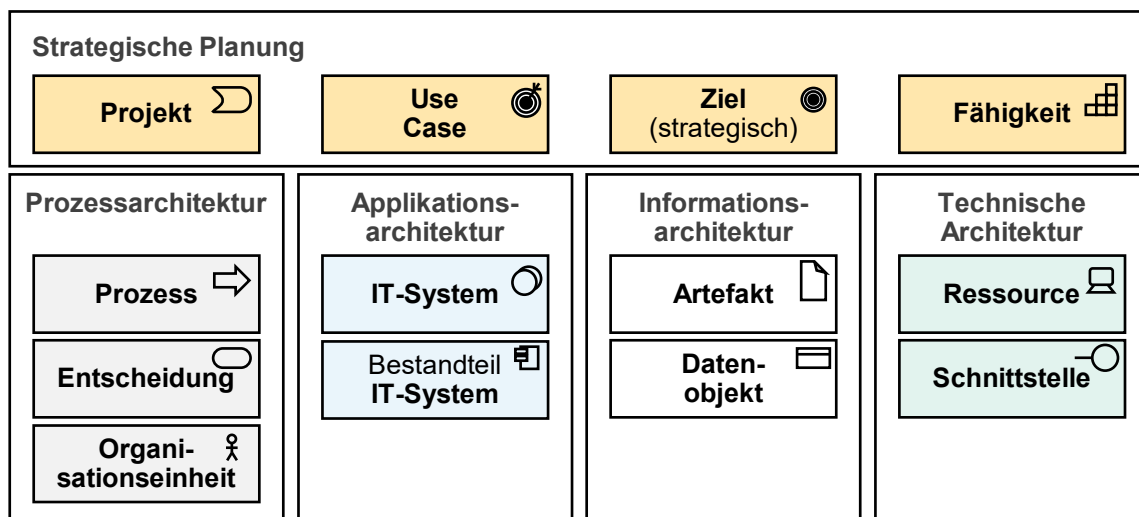


Bild 4-13: Spezialisierung des ArchiMate Metamodells aufbauend auf [Ope24-ol]

Zur Spezialisierung des Metamodells werden ein für die Ausarbeitung dediziertes Farbschema, eigene Objektbezeichnungen und erlaubte assoziierte Verbindungen basierend auf dem Standard definiert. Die Modellelemente sind somit in den Oberkategorien der

<sup>13</sup>Vergleiche hierzu LeanIX Metamodell v4, Abgerufen am 23.06.2024:  
<https://docs-eam.leanix.net/docs/meta-model>

**strategischen Planung, Prozessarchitektur, Applikationsarchitektur, Informationsarchitektur** und **technischen Architektur** angeordnet. Eine detaillierte Version ist in Anhang A2.6 abgebildet. Im darauffolgenden Kapitel (siehe Anhang A2.7) werden außerdem Schnittstellen zu anderen Metamodellen diskutiert. Eigenschaften und Attribute je Modellelement werden nicht vorgegeben, können aber anwendungsbezogen etabliert werden (z. B. Use Case ID oder Datenbankklarname).

#### 4.4.5 Vernetzung der Partialmodelle

In allen Phasen des Vorgehens wird das Modellierungskonzept durchgehend als Medium zur Strukturierung, Erarbeitung, Kommunikation und Dokumentation der Teilergebnisse genutzt. Das durchgängige Konzept zur **Vernetzung der Partialmodelle** kann durch unternehmensspezifische Sichten ergänzt werden. Eine weitergehende Ausgestaltung in diese Richtung gehört nicht zum Kern dieser Ausarbeitung, stellt aber eine mögliche Erweiterung dar. In der praktischen Anwendung gilt es, eine für den Zeitpunkt der Modellierung angemessene Balance zwischen Modellierungstiefe, Modellierungsaufwand und Zweckmäßigkeit zu finden. Dafür ist das Modellierungskonzept iterativ anzuwenden. Dementsprechend ist im Sinne der Anwendung im Vorgehensmodell mit groben Darstellungen (z. B. nur übergeordnete Prozesse) zu beginnen, die anlassbezogen zu detaillieren sind. Der höchste Detaillierungsgrad wird bei der Übergabe an die Umsetzung (und bei weiterer Verwendung auch danach) erreicht.

Detaillierte Hilfestellungen zur Wahl der Modellierungstiefe liegen nicht im Fokus dieser Ausarbeitung. Generell wird aber ein pragmatischer, gegebenenfalls semiformaler Umgang mit dem Modellierungskonzept zum Zwecke der Praxistauglichkeit vorgeschlagen. Bei steigender Umweltkomplexität und Menge an zu planenden Use Cases ist ein entsprechend stringenteres Vorgehen zu wählen.

Alle Partialmodelle sind so gestaltet, dass sie konsistent miteinander verwendet werden können. Jedes Partialmodell bietet aber auch alleinstehend einen Mehrwert. Aus den definierten Partialmodellen und der Spezialisierung ergibt sich implizit ein Vernetzungskonzept. Tabelle 4-2 gibt einen Überblick über die Wechselwirkungen zwischen den verschiedenen Elementen der Spezialisierung und den Partialmodellen. Die Partialmodelle stellen keine eindimensionale Sicht auf eine Architekturdomäne (z. B. nur Prozess oder Architektur) dar. Vielmehr kombinieren sie verschiedene Architekturdomänen (z. B. Daten und Prozesse) für einen adäquaten Einsatz bei der Planung von Analytics.

Tabelle 4-2: Übersicht über die Zusammenhänge zwischen den Partialmodellen und der Spezialisierung (X = in diesem Partialmodell verwendet)

Zusammenhang von Partialmodell und Metamodellelement		verwendete Elemente									
		Projekt (Strategie)	Use Case (Strategie)	Strategisches Ziel (Strategie)	Fähigkeit (Strategie)	Prozess (Prozesse)	Entscheidung (Prozesse)	Organisationseinheit (Prozesse)	Übergeordnetes IT-System (Applikation)	Bestandteil IT-System (Applikation)	Ressource (Technisch)
vom Partialmodell											
Use Case Portfolio			X	X							
Roadmap zur Use Case Planung		X	X								
Prescriptive Analytics Capability Map					X						
Prozessmodell			X			X			X	X	X
Applikationsarchitektur										X	
Datenkatalog											
Technische Architektur in der Produktion										X	
Use Case Interaktion			X			X	X	X			
Use Case Architektur			X		X				X	X	X
Use Case Daten											
Use Case Pipeline								X		X	X

Der **Zusammenhang von Partialmodell und Metamodellelement** dient der Konsistenz und Wiederverwendbarkeit der erarbeiteten Inhalte. Wenn beispielsweise eine **Datenbank** für einen **Use Case** verwendet wird, so ist diese in der **Use Case Architektur**, im **Datenkatalog** und, falls bereits implementiert, in der **Applikationsarchitektur** des betrachteten Systems wiederzufinden. Das heißt, die Spezialisierung erlaubt direkte und indirekte Kopplungen zwischen Prozess-, Applikations-, Informations- und technischer Architektur. Weiterhin sind die zwischen den Modellelementen erlaubten Verbindungen beschränkt (siehe Anhang A2.6).

#### 4.4.6 Verwendung der Partialmodelle

Für die Partialmodelle ergibt sich eine optimale Reihenfolge zur Verwendung im Kontext des Vorgehensmodells aus Kapitel 4.3.3. Alle Modelle werden im Rahmen des Vorgehens kontinuierlich verfeinert, dennoch stehen bestimmte Partialmodelle in vorgegebenen Schritten im Zentrum. Durch die Reihenfolge zur iterativen Befüllung und Bearbeitung der verschiedenen Partialmodelle werden diese unmittelbar in Abhängigkeit gesetzt. Die Befüllung der Partialmodelle wird durch entsprechende Artefakte zur Unterstützung vereinfacht (vgl. Kapitel 4.5.1). Die initiale Erstellung und **Verwendung der Partialmodelle** im übergeordneten Vorgehensmodell ist in Bild 4-14 visualisiert. Dem Anhang sind Kurzübersichten über die jeweils formal erlaubten Modellierungselemente je Sicht zu entnehmen (siehe Anhang A2.8). Auf die Artefakte zur Befüllung der Partialmodelle wird im folgenden Kapitel eingegangen.

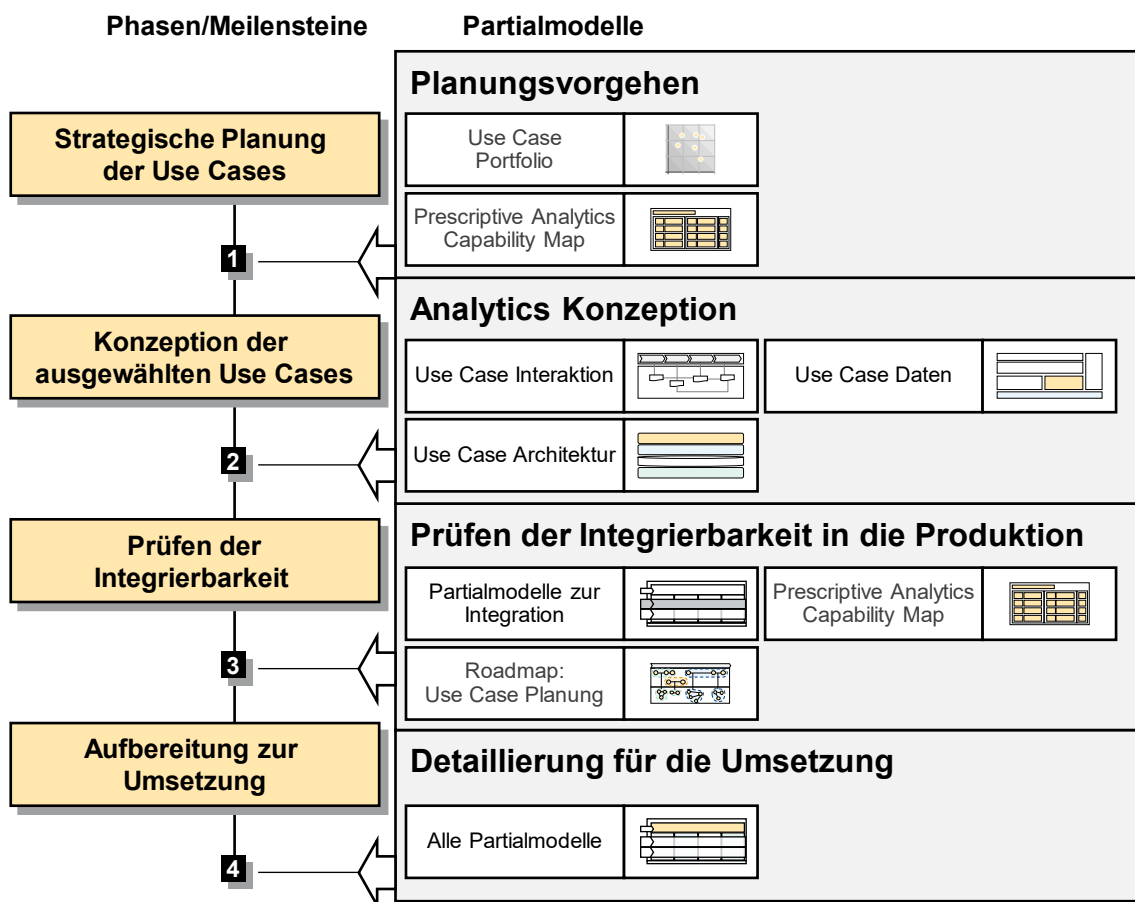


Bild 4-14: Verwendung der Partialmodelle im übergeordneten Vorgehensmodell

In der Phase der **strategischen Planung** werden die Use Cases in das **Use Case Portfolio** eingeführt. Die **Prescriptive Analytics Capability Map** bildet die im Unternehmen vorliegenden Capabilities ab.

Während der **Konzeption der ausgewählten Use Cases** wird die **Use Case Interaktion** definiert. Da die Use Case Interaktion Prozesse und Entscheidungen enthält, ist sie unmittelbar mit dem Prozessmodell verknüpft. Aufbauend auf der Use Case Interaktion wird eine initiale **Use Case Architektur** konzipiert. Diese beinhaltet neben Use Cases (Schnittstelle zum Use Case Portfolio) auch Datenbanken, Capabilities und Datenquellen. Diese verweisen jeweils auf die Applikationsarchitektur, den Datenkatalog und die technische Architektur in der Produktion. Die Verknüpfung zum Datenkatalog wird zusätzlich durch die Definition der relevanten Daten in der Übersicht zu den **Use Case Daten** hergestellt.

In der Phase der **Prüfung der Integrierbarkeit** werden alle Partialmodelle aufgegriffen und iterativ verfeinert. Dies beinhaltet die Analyse von Synergien und Schnittstellen. Die **Roadmap zur Use Case Planung** wird erstellt und enthält Verknüpfungen zu den Use Cases aus dem Portfolio und den zu erlangenden Datenobjekten aus dem Datenkatalog. Die **Prescriptive Analytics Capability Map** wird für eine Fit-Gap Analyse genutzt.

Bei der **Aufbereitung zur Umsetzung** steht primär die Ausgestaltung einer initialen Prescriptive Analytics Pipeline im Fokus. **Alle Partialmodelle** werden genutzt.

## 4.5 Artefakte zur Unterstützung

Es wird ein Überblick über die **Artefakte zur Unterstützung** im übergeordneten Vorgehen gegeben. Die Artefakte dienen der Befüllung der Partialmodelle und damit dem übergeordneten Zweck der Spezifikation von Prescriptive Analytics Lösungen in der Produktion.

**Kapitel 4.5.1** gibt einen Überblick über die Einordnung der Artefakte im Modellierungskonzept. Darauf aufbauend werden die Prescriptive Analytics Use Case Transformation Canvas in **Kapitel 4.5.2** und die generische Prescriptive Analytics Capability Map in **Kapitel 4.5.3** vorgestellt. Die Prescriptive Analytics Data Canvas wird in **Kapitel 4.5.4** präsentiert. In **Kapitel 4.5.5** wird die Referenzarchitektur für die Integration von Prescriptive Analytics Use Cases in die Produktion erläutert. **Kapitel 4.5.6** stellt das Artefakt der Referenzpipeline für Prescriptive Analytics Use Cases vor.

### 4.5.1 Einordnung der Artefakte

Die Artefakte werden in Form von Workshopmethoden, Referenzarchitekturen und Referenzpipelines zur Verfügung gestellt. Sie dienen der effizienten Befüllung der Partialmodelle des Modellierungskonzepts.

Bild 4-15 gibt einen Überblick, welche Artefakte zum Füllen welches Partialmodells im Modellierungskonzept verwendet werden. Dies zeigt die **Einordnung der Artefakte** im Modellierungskonzept. Die Bedarfe je Artefakt und respektivem Partialmodell wurden in Kapitel 4.4.3 hergeleitet. Alle Artefakte werden nun genauer erläutert und verortet. Für

eine detaillierte Beschreibung der Zusammenhänge, Herleitung und Evaluation wird auf die jeweilige Teilveröffentlichung verwiesen.

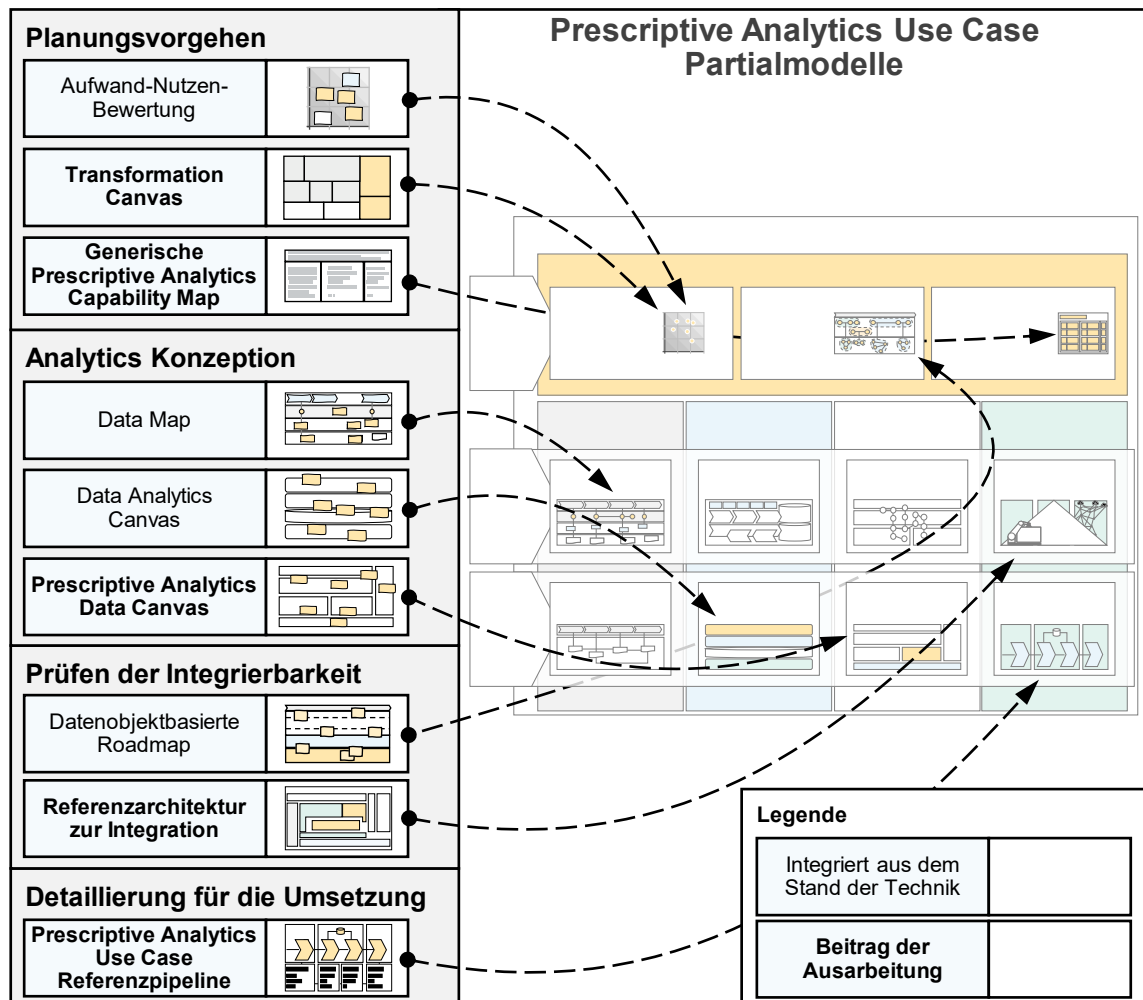


Bild 4-15: Zusammenhang von Artefakten zur Unterstützung und Partialmodellen

Zur Dokumentation der Anwendung der Artefakte dienen die einzelnen **Prescriptive Analytics Use Case Partialmodelle**. Die Partialmodelle des Datenkatalogs, der Applikationsarchitektur und der Use Case Interaktion werden nicht gesondert unterstützt, da in beiden keine Besonderheiten für Prescriptive Analytics vorliegen. Für die Erstellung von Datenkatalogen wird auf [ESM+21, JO23, LLE+20] verwiesen. Zur Modellierung der Applikationsarchitektur wird auf den TOGAF Standard verwiesen [Togaf10]. Für die Use Case Architektur wird eine Blaupause in Anhang A2.8 bereitgestellt. Tabelle 4-3 gibt einen Überblick über die Verwendung je Artefakt im übergeordneten Vorgehensmodell.

Tabelle 4-3: Überblick über die Verwendung je Artefakt in der Ausarbeitung

<b>Artefakt</b>	<b>Zweck im übergeordneten Vorgehensmodell</b>	<b>Vorgehensmodell zur Anwendung</b>
Aufwand-Nutzen-Bewertung [GDE+19, S. 198]	Unterstützung bei der Priorisierung verschiedener Use Cases im gleichen System unter Observation.	Anhang A4.3
<b>Use Case Transformation Canvas</b> [WNG+25]	Workshopmethodenbasierte Unterstützung bei der Ideation und Weiterentwicklung neuer und vorhandener Prescriptive Analytics Use Case Ideen.	Kapitel 4.5.2
<b>Generische Prescriptive Analytics Capability Map</b> [WLB+25]	Workshopmethodenbasierte Unterstützung bei der Ermittlung der relevanten und vorhandenen Capabilities für die ausgewählten Use Cases in einer gegebenen Organisation.	Kapitel 4.5.2
Data Map [JEK+19]	Workshopmethodenbasierte Unterstützung bei der Aufnahme relevanter Datenobjekte im Prozess.	Kapitel 3.2.3
Analytics Canvas [KJR+18]	Workshopmethodenbasierte Unterstützung bei der Konzeption einer ersten Use Case Architektur.	Kapitel 3.2.2
<b>Prescriptive Analytics Data Canvas</b> [WMK+24]	Workshopmethodenbasierte Unterstützung bei der Ermittlung der relevanten Datenobjekte für den Prescriptive Analytics Use Case.	Kapitel 4.5.4
Roadmap [IHB+18, S. 976, VP23, S. 3]	Unterstützung bei der sachlogischen und zeitlichen Sequenzierung von Aktivitäten die zur Umsetzung eines Use Cases beitragen.	Anhang A4.8
<b>Referenzarchitektur zur Integration von Prescriptive Analytics</b> [WMN+24]	Unterstützung beim Design der technischen Integration der konzeptionierten Prescriptive Analytics Use Cases.	Kapitel 4.5.5
<b>Referenzpipeline für Prescriptive Analytics Use Cases</b> [WMW+23]	Unterstützung bei der Konzeption der Pipeline des Prescriptive Analytics Use Cases.	Kapitel 4.5.6

#### 4.5.2 Prescriptive Analytics Use Case Transformation Canvas

Das Artefakt der Prescriptive Analytics Use Case Transformation Canvas kommt in **Phase eins** des übergeordneten Vorgehensmodells zur Anwendung (siehe Kapitel 4.3.3.1). Diese Phase der strategischen Planung dient der initialen Priorisierung eines Sets an Use Cases, um dieses für die Konzeption auszuwählen. Die **Prescriptive Analytics Use Case Transformation Canvas** wird zur Spezifikation von Prescriptive Analytics Use Case Ideen verwendet. Die Canvas baut auf der Taxonomie aus Kapitel 4.2.2 auf. Diese wurde auf der *CIRP CMS* als [WNG+25] vorveröffentlicht. Die Entwicklung basiert auf der Forschungsmethode nach NICKERSON ET AL. [NVM13]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die Prescriptive Analytics Use Case Transformation Canvas wird vom Industrie 4.0 Manager zusammen mit dem Analytics Architekten und Domänenexperten verwendet. Ihr Zweck ist die initiale Spezifikation von Use Case Ideen für Prescriptive Analytics. Diese Ideen gehen von einem **vorhandenen Data Analytics Use Case** aus. Dieser wird „transformiert“, indem geprüft wird, inwieweit auf diesem ein Prescriptive Analytics Use Case aufgesetzt werden kann. Die resultierende Canvas ist in Bild 4-16 dargestellt. Die Schnittstellen der Canvas zu den anderen Partialmodellen ist abgebildet.

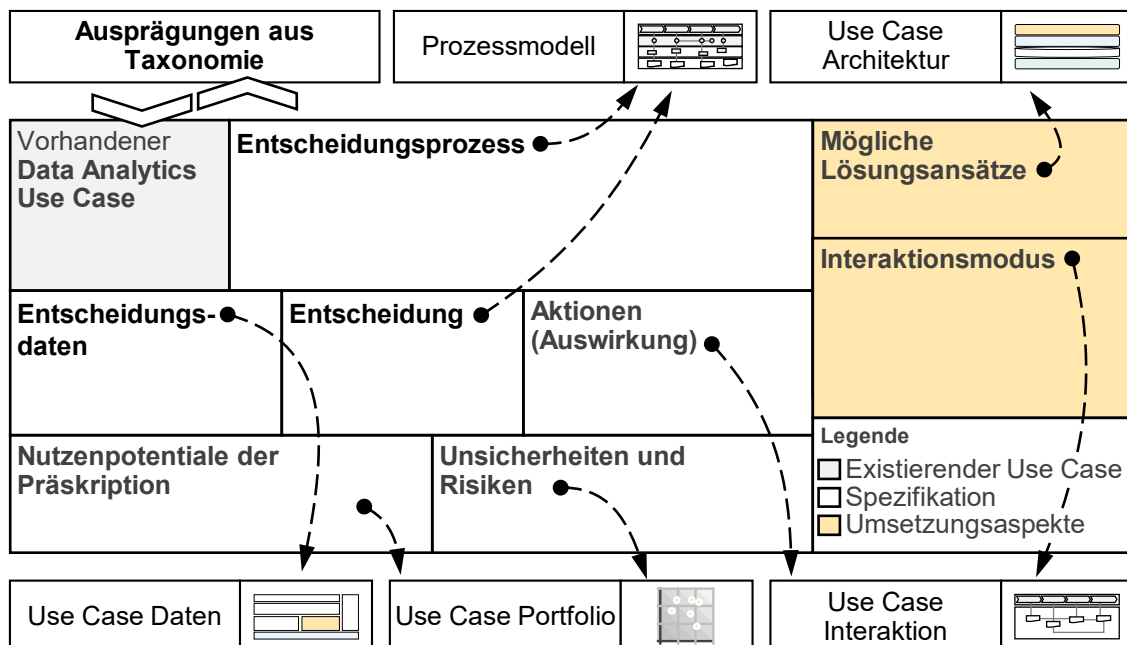


Bild 4-16: Prescriptive Analytics Use Case Transformation Canvas aufbauend auf Kapitel 4.2.2

Zur Anwendung der Canvas in einem Workshopformat wird zuerst der **vorhandene Data Analytics Use Case** kurz vorgestellt. Darauf aufbauend werden der damit verbundene **Entscheidungsprozess** und die eigentliche **Entscheidung** genauer beschrieben. Aufbauend auf dieser Diskussionsgrundlage werden die restlichen Felder (Entscheidungsdaten,

Aktionen, Nutzenpotenziale, Unsicherheiten und Risiken) ausgefüllt. Für die **Entscheidungsdaten** werden alle vorhandenen Daten und Dokumente gesammelt, die präskriptive Informationen enthalten können. Für die **Aktionen** wird aufgenommen, welche Handlungen aus der eigentlichen Präskription abgeleitet werden sollen. Die Felder der **Nutzenpotenziale der Präskription** und der **Unsicherheiten und Risiken** dienen der Aufbereitung des Einflusses des Use Cases auf das System unter Observation.

Basierend auf der initialen Charakterisierung der Use Case Idee werden mögliche **Lösungsansätze** und ein möglicher **Interaktionsmodus** mit der Lösung (z. B. Audit System, siehe Kapitel 2.4.1) diskutiert. Für alle Felder aus der Canvas sind Leitfragen im Anhang beigefügt (siehe Anhang A2.9). Ergebnis der Anwendung der Canvas ist eine semi-formale Beschreibung einer Prescriptive Analytics Use Case Idee. Die Ergebnisse aus den Feldern „**mögliche Lösungsansätze**“ und **Interaktionsmodus** dienen der weiteren Konzeption als Grundlage.

### 4.5.3 Generische Prescriptive Analytics Capability Map

Das Artefakt der generischen Prescriptive Analytics Capability Map kommt in **Phase eins** des übergeordneten Vorgehensmodells zur Anwendung (siehe Kapitel 4.3.3.1). Diese Phase der strategischen Planung dient der initialen Priorisierung einer Menge an Use Cases, um diese für die Konzeption auszuwählen. Neben der Phase eins des Vorgehens wird sie auch in Phase drei für eine erneute Analyse der initial vorgenommenen Bewertung verwendet. Die **generische Prescriptive Analytics Capability Map**<sup>14</sup> für die Produktion wird zur Instanziierung einer unternehmensspezifischen Anzahl an Capabilities verwendet. Sie wurde auf der *CIRP CMS* als [WLB+25] vorveröffentlicht. Die Entwicklung basiert auf der Forschungsmethode nach VAN RIEL UND POELS [vP23]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die Capability Map wird vom Industrie 4.0 Manager verwendet. In der Praxis werden zur Strukturierung der Analyse der Unternehmensfähigkeiten Capability Maps verwendet. Diese gibt es mit einem Fokus auf das ganze Unternehmen oder spezifische Subfelder wie der generativen KI (vgl. [CDK23-ol, Lea24-ol]). Basierend auf der Empfehlung nach LANKHORST wird die Capability Map im Detailgrad auf drei Level beschränkt [Lan17, S. 210]. Es existieren je Oberkategorie zwei Unterkategorien. Dementsprechend ist die Capability Map dreistufig aufgebaut. Zur Vereinfachung der Anwendung kann nur mit den ersten zwei Capability-Stufen gearbeitet werden. Für eine vollumfängliche Bewertung werden alle drei Stufen benötigt. Ein Überblick über die Level eins und Level zwei Capabilities der generischen Capability Map ist in Bild 4-17 dargestellt. Neben der über-

---

<sup>14</sup> Für die Definition des Begriffs der Capability Map wird auf Kapitel 2.5.4 verwiesen.

geordneten Darstellung aus Bild 4-17 wird im Anhang A2.10 die Capability Map inklusive der Level drei Capabilities bereitgestellt. Ergänzt wird diese durch eine kurze Definition jeder Capability.

Die generische Capability Map muss unternehmensspezifisch instanziiert werden. Es liegt keine direkte Verknüpfung von Use Case und jeder Capability vor, weil der gewählte Betrachtungswinkel die Capabilities der Organisation beschreibt und keinen direkten Use Case Bezug aufweist.

<b>Analytics Strategie-management</b>	Analytics Strategie-entwicklung	Analytics Leitplanken Definition	
<b>Analytics Portfolio-management</b>	<b>Analytics Use Case Entwicklung</b>		<b>Analytics Daten Bereitstellung</b>
Strategische Use Case Planung	Use Case Konzeption	Analytics Operations	Daten Engineering
Analytics Architektur-management	Analytics Governance	Analytics Entwicklung	Daten Management
Analytics IT-Setup-Management	Use Case Architekturintegration	Analytics Insight Generation	D3M Daten Handling
Projektmanagement	Data-Driven Decision Making (D3M)	Analytics Insights Nutzung	Shopfloor Daten Handling
Analytics Setup Koordination			Shopfloor Daten Connectivity
<b>Legende</b>		D3M = Data Driven Decision Making	
Für Analytics relevante Capability	Durch die Ausarbeitung befähigte Capability	Insbesondere für Prescriptive Analytics relevante Capability	

Bild 4-17: Level zwei Ansicht der generischen Capability Map für die Entwicklung von Prescriptive Analytics Use Cases in der Produktion

Neben dem **Analytics Strategie Management**, **Analytics Portfolio Management** und der **Analytics Use Case Entwicklung** steht die übergeordnete Fähigkeit der **Analytics Daten Bereitstellung** im Vordergrund. Die übergeordnete Struktur orientiert sich an den adressierten Perspektiven des Modellierungskonzepts (siehe Kapitel 4.4.2). Die oberste Ebene (Analytics Strategie Management) sammelt Capabilities mit einem Fokus auf der Strategieentwicklung und Leitplanken Definition. Das Analytics Portfoliomanagement adressiert die Aspekte im Vorgehen, die das übergreifende Management einzelner Use Cases betreffen. Der Bereich der Use Case Entwicklung bildet ein Sammelbecken für alle Capabilities, die unmittelbar mit der Lösungsentwicklung zu tun haben. Der Bereich der Datenbereitstellung fokussiert sich auf die Befähiger-Themen, welche die richtigen Daten zum richtigen Zeitpunkt für die Verarbeitung in einem Analytics Use Case zur Verfügung stellen.

#### 4.5.4 Prescriptive Analytics Data Canvas

Das Artefakt der Prescriptive Analytics Data Canvas kommt in **Phase zwei** des übergeordneten Vorgehensmodells zur Anwendung (siehe Kapitel 4.3.3.2). Basierend auf den initial ausgewählten Use Cases werden Konzepte für die Umsetzung erstellt. Die **Prescriptive Analytics Data Canvas** dient der Befüllung der Datenarchitektur zur Konzeption eines einzelnen Prescriptive Analytics Use Cases. Sie wurde auf der *CPSL* als [WMK+24] vorveröffentlicht. Die Entwicklung basiert auf der Forschungsmethode DSRM nach PEFFERS ET AL. [PTR+07]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die Prescriptive Analytics Data Canvas wird vom Analytics Architekten zur Ermittlung der für den Use Case relevanten und verfügbaren Daten angewendet. Dafür werden die möglichen Datenobjekte gesammelt. In einem zweiten Schritt wird deren Verfügbarkeit bewertet. Ein Überblick über die Ebenen der Canvas ist in Bild 4-18 visualisiert.

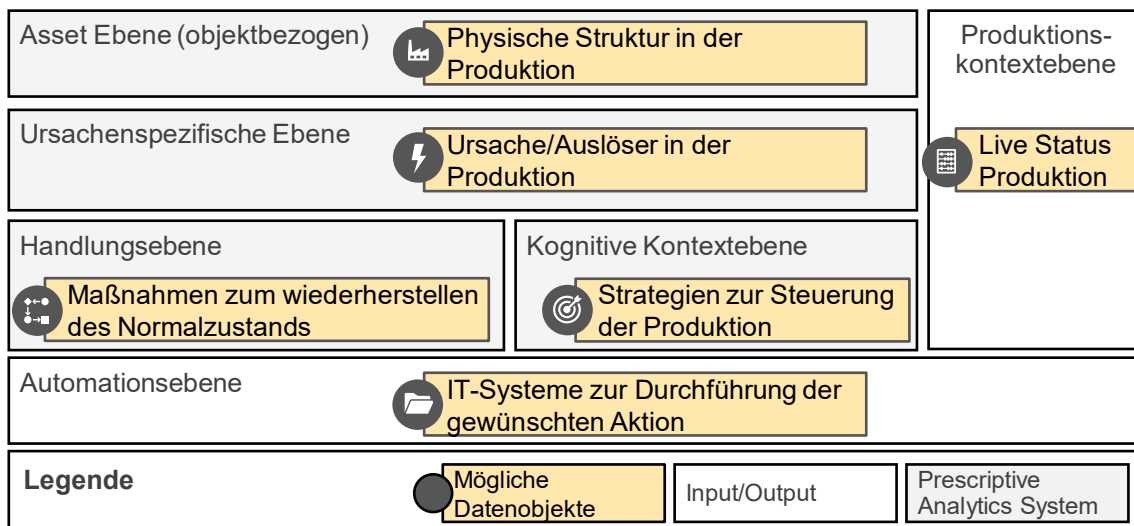


Bild 4-18: Prescriptive Analytics Data Canvas

In der **Asset Ebene** werden Daten zur physischen Struktur in der Produktion verortet. Ein Beispiel dafür sind verschiedene Teile der Fabrik inklusive Metainformationen. Für die Asset Ebene gibt es zwei verschiedene Grundtypen von Analytics Use Cases. Einzelne, die nur in einem sehr begrenzten System unter Observation funktionieren und solche, die übergreifende Konsequenzen haben. Letztere erfordern eine allgemeine Zuordnung oder Korrelation, wo in dem beobachteten System ein Fehler entdeckt wurde [WML+23]. Die **ursachenspezifische Ebene** dient dazu, eine Zuordnung zwischen dem Auslöser der Präskription (z. B. Maschinenstörung) und den möglichen direkten und nachgelagerten Aktionen (aus der Handlungsebene) zu schaffen. Das Prescriptive Analytics System wird durch die **Produktionskontextebene** mit Kontextdaten angereichert. Dies unterstützt die kontextbasierte Entscheidungsfindung. Der Kontext kann auf bedingten Informationen (deskriptiv) oder prädiktiven Algorithmen und anderen Optimierungsansätzen in demsel-

ben System unter Observation beruhen. Die **Handlungsebene** systematisiert die erforderlichen Maßnahmen zur Wiederherstellung eines normalen Produktionszustands. Datenelemente dieser Ebene müssen mit Elementen aus der ursachenspezifischen Ebene verknüpft werden. Die **kognitive Kontextebene** dient dazu, die menschlichen Faktoren bei der Entscheidungsfindung wie Szenarien, Strategien oder Ziele darzustellen. Auch wenn nicht jeder Algorithmus diese Datenpunkte aufnehmen kann, so sind sie doch für die Gestaltung solcher Systeme unerlässlich. Die Ebene fasst alle entscheidungsrelevanten Restriktionen und Richtlinien zusammen. Die **Automatisierungsebene** stellt eine Abbildung von Automatisierungssystemen wie zum Beispiel die Produktionsplanung oder andere Instanzen dar, die eine direkte Aktion auslösen und durchführen können. Die Automatisierungsebene und die Produktionskontextebene dienen hauptsächlich als Input oder Output Verbindung.

Die Art der benötigten Daten steht in direktem Zusammenhang mit dem Grad der Entscheidungsunterstützung, der für den jeweiligen Use Case und das zu entwickelnde Prescriptive Analytics System angestrebt wird (vgl. Kapitel 2.4.1). Bild 4-19 dient dazu, die Daten aus der Prescriptive Analytics Data Canvas zu einem damit möglichen Grad der Entscheidungsunterstützung zuzuordnen. Es wird eine Verbindung zwischen den Datenelementen und dem gewählten Interaktionsmodus der Entscheidungsunterstützung im Fall des Prescriptive Analytics Use Cases hergestellt.

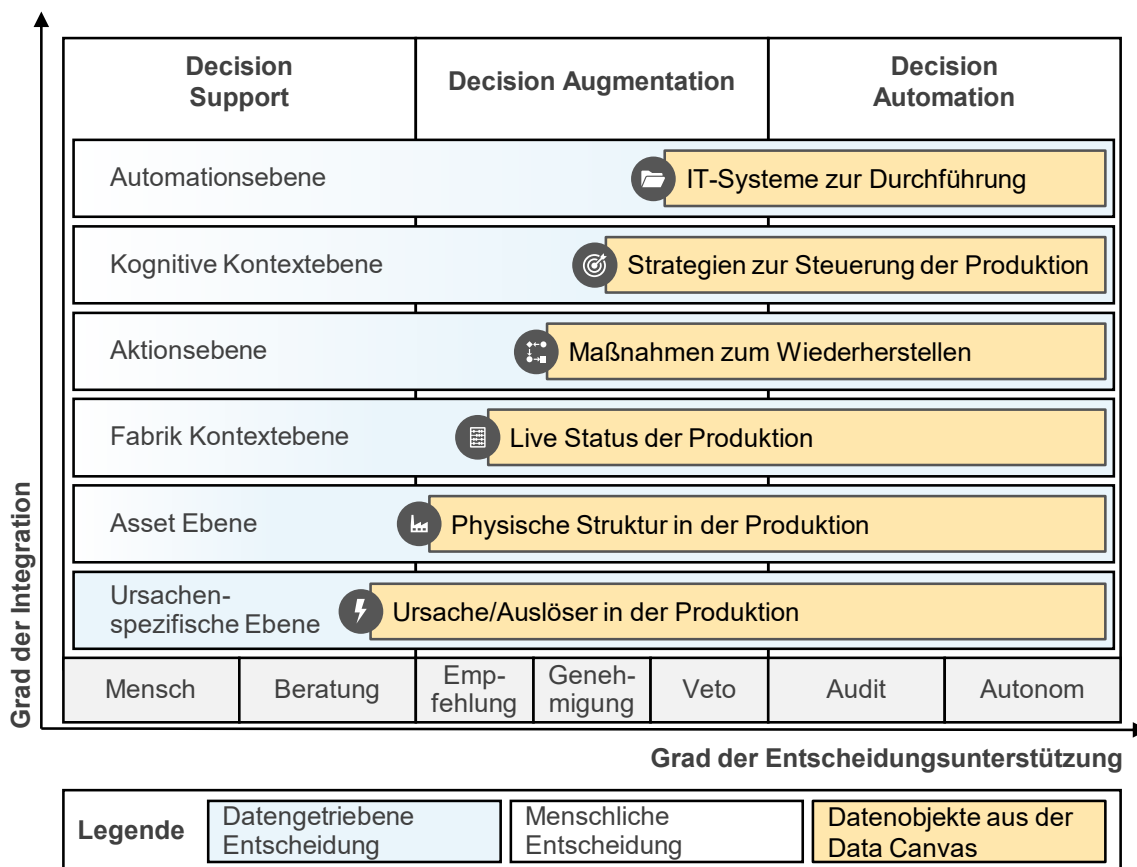


Bild 4-19: Zuordnung der Ebenen der Prescriptive Analytics Data Canvas zu dem möglichen Grad der Entscheidungsunterstützung (siehe Kapitel 2.4.2)

Die Spalte „**Grad der Entscheidungsunterstützung**“ stellt die Kategorien für die Entscheidungsunterstützung bis zur Vollautomatisierung nach GARTNER dar (siehe Kapitel 2.1.3). Der „**Grad der Integration**“ wird über die Prescriptive Analytics Data Canvas definiert. Bei steigendem Grad an Integration und Entscheidungsunterstützung wird die Entscheidung immer mehr in den Bereich der **datengetriebenen Entscheidungen** verlagert. Die **menschliche Entscheidung** rückt in den Hintergrund. Dies dient als Grundlage für die Bestimmung eines minimalen Satzes von Datenobjekten, die für den benötigten Zielreifeegrad des Use Cases benötigt werden. Der Zielreifeegrad stammt aus der Prescriptive Analytics Use Case Transformation Canvas und wird hier überarbeitet.

#### 4.5.5 Referenzarchitektur zur Integration von Prescriptive Analytics

Die Referenzarchitektur kommt in **Phase drei** und **Phase vier** des übergeordneten Vorgehensmodells zur Anwendung (siehe Kapitel 4.3.3.3 und Kapitel 4.3.3.4). Diese Phasen beschreiben das Prüfen der Use Cases für die Integration in die bestehende Architektur, die Synergie- und Schnittstellenbetrachtung zwischen den Use Cases und den Schritt der Aufbereitung zur Umsetzung eines Use Cases. Die **Referenzarchitektur zur Integration von Prescriptive Analytics** dient als Grundlage zur Strukturierung der Integration einzelner Use Cases in die existierende Applikations- und technische Architektur in der Produktion. Sie unterstützt die Integration durch das Aufzeigen der benötigten logischen Verbindungen zwischen den einzelnen Systemelementen. Die Referenzarchitektur wurde im MDPI Journal *Mathematics* als [WMN+24] vorveröffentlicht. Ein Überblick zu relevanter Literatur aus diesem Journalbeitrag wurde in Kapitel 3.3.4 vorgestellt. Die Entwicklung basiert auf der Forschungsmethode nach GALSTER UND AVGERIOU [GA11]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die Referenzarchitektur zur Integration von Prescriptive Analytics wird vom Analytics Architekten verwendet. In einem ersten Schritt gilt es, die Referenzarchitektur zu instanzieren. Die Instanziierung selbst wird durch die Verwendung der Elemente des Metamodells (siehe Kapitel 4.4.4) unterstützt. Alle Elemente der Referenzarchitektur müssen für den vorliegenden Betrachtungsraum detailliert beschrieben werden. Im Rahmen der Ausarbeitung wird die Verwendung als Blaupause für die Modellierung der Applikations- und technischen Architektur verwendet. Ein konzeptioneller Überblick über die Referenzarchitektur ist in Bild 4-20 dargestellt.

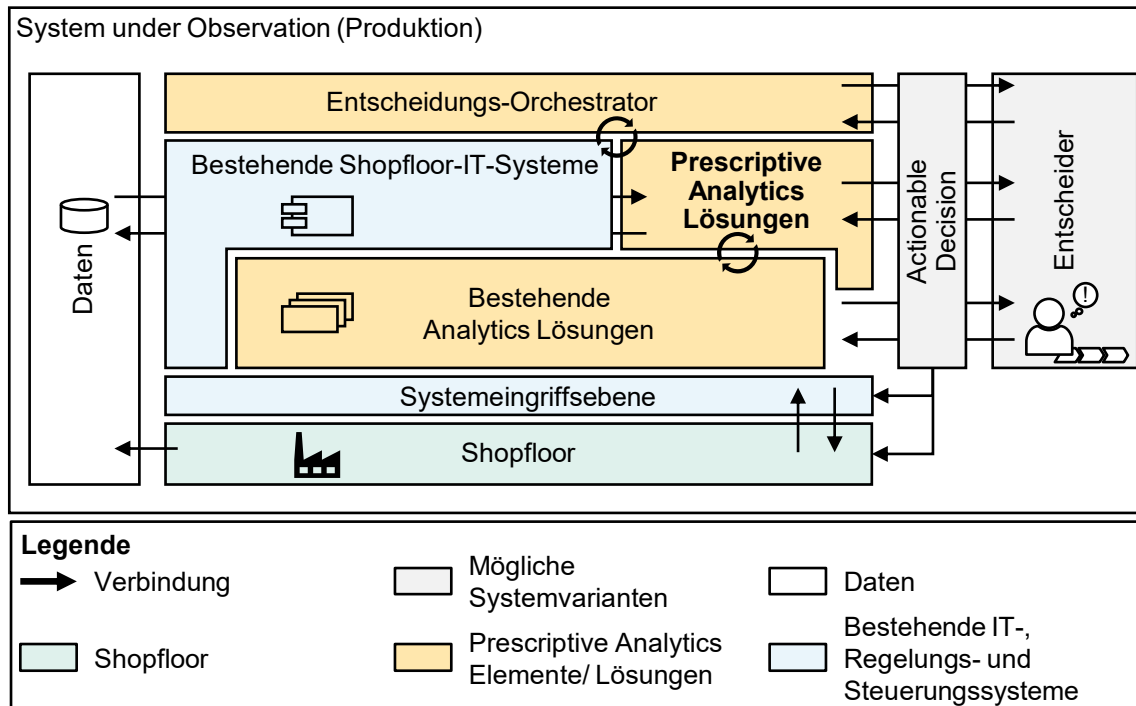


Bild 4-20: Konzeptioneller Überblick der Referenzarchitektur zur Integration von Prescriptive Analytics Use Cases in die Produktion

Die Elemente **Systemeingriffsebene**, **Daten** und **Shopfloor** der Referenzarchitektur bauen auf der existierenden Daten-Infrastruktur der Produktion (siehe Kapitel 2.2.3) auf. Weiterhin sind Entscheidung (**Actionable Decision**) und **Entscheider** bereits Teil der Produktion. Darin eingepasst sind die **bestehenden Shopfloor-IT-Systeme**. Als neue Elemente kommen **bestehende Analytics Lösungen**, **Prescriptive Analytics Lösungen** und ein **Entscheidungs-Orchestrator** hinzu. Somit besteht die Referenzarchitektur aus den folgenden Elementen:

- **Shopfloor:** In der Produktion vorliegende Elemente sind als „**Shopfloor**“ vereinfacht repräsentiert.
- **Bestehende Shopfloor-IT-Systeme:** IT-Systeme unterscheiden sich hinsichtlich ihrer allgemeinen Funktion, ihres Umfangs und ihres Vernetzungsgrads (siehe Automatisierungspyramide in Kapitel 2.2.1).
- **Systemeingriffsebene:** Diese Ebene repräsentiert alle echtzeitorientierten Systeme in der Produktion, die nicht auf Analytics Use Cases basieren. Dies kann alle relevanten Datenquellen für die Analytics Use Cases wie Algorithmen zur Regelung und Steuerung umfassen (vgl. [DAG13]). Ansätze aus dem Bereich des digitalen Zwillings (vgl. [LDK+24]) und andere Systeme, die berechtigt sind in die Fertigungsprozesse einzugreifen, sind inkludiert.
- **Daten:** Der Block der Daten repräsentiert den logischen Datenfluss durch den IT-Stack der Produktion (horizontale und vertikale Verbindung). Hier werden lediglich etablierte Elemente integriert. Die Datenschicht wird mit zusätzlichen Informationen verfeinert. Es werden verschiedene Arten von Daten betrachtet, die für Prescriptive

Analytics Use Cases und allgemeine Analytics Use Cases relevant sind. Dazu zählen Expertenwissen [LBA+20, S. 67], Entscheidungsdaten und historische Produktionsdaten [BLA+21]. Diese Daten können in der für die jeweilige Umgebung am besten geeigneten Form zur Verfügung gestellt werden (z. B. via Graphen [Hod21]).

- **Bestehende Analytics Lösungen und Prescriptive Analytics Lösungen:** Diese Blöcke repräsentieren die in Kapitel 4.5.6 beschriebenen Prescriptive Analytics und generellen Analytics Lösungen als zu integrierenden Block. Die zu integrierenden Prescriptive Analytics Use Cases unterscheiden sich hinsichtlich der Dringlichkeit der Entscheidung (ad-hoc bis langfristig) [ER18, S. 11]. Der Grad der Verflechtung und der Geltungsbereich der Entscheidung sind sehr unterschiedlich [WML+23]. Dasselbe gilt für die Auswirkungen einer individuellen Entscheidung [BHF+23, S. 36]. Die Ziele, Arten und Ergebnisse von Entscheidungen sind ebenfalls vielfältig [LBM22, S. 115]. Auch die Art der Interaktion mit dem Entscheidungsträger (Mensch/Lösung) sorgt für unterschiedliche Merkmale eines Use Cases [RKK+20, S. 10].
- **Actionable Decisions:** Sie stellen das Kernelement der konzeptionellen Architektur dar. Sie verbinden die Entscheidungsträger und die jeweiligen Systeme (siehe Kapitel 2.1.3).
- **Entscheider:** Bis zur vollständigen Autonomie werden Menschen immer in Entscheidungen oder deren Steuerung eingebunden sein. Basierend auf den Stufen der hybriden Entscheidungsfindung nach GARTNER [Gar22a] wird zwischen den folgenden Entscheidungsinteraktionsschemata unterschieden: Entscheidungsbestätigung, Entscheidungsveto, Entscheidungsprüfung und Entscheidungsnachfrage („Muss eine Entscheidung getroffen werden?“).
- **Entscheidungs-Orchestrator:** Dieses Element dient der übergeordneten Priorisierung und Entscheidungsfindung bei Zielkonflikten. Auch wenn sich das Konzept der Industrie 4.0 auf die Umsetzung einer dezentralen Entscheidungsfindung bezieht (vgl. [HPO16]), muss dennoch ein globales Optimum eingestellt und erreicht werden.

Die Elemente bilden einen Überblick zur Integration der Entscheider und Prescriptive Analytics Use Cases in der Produktion. Aufbauend auf dem konzeptionellen Überblick wird die detaillierte Sicht auf die Referenzarchitektur in Bild 4-21 bereitgestellt.

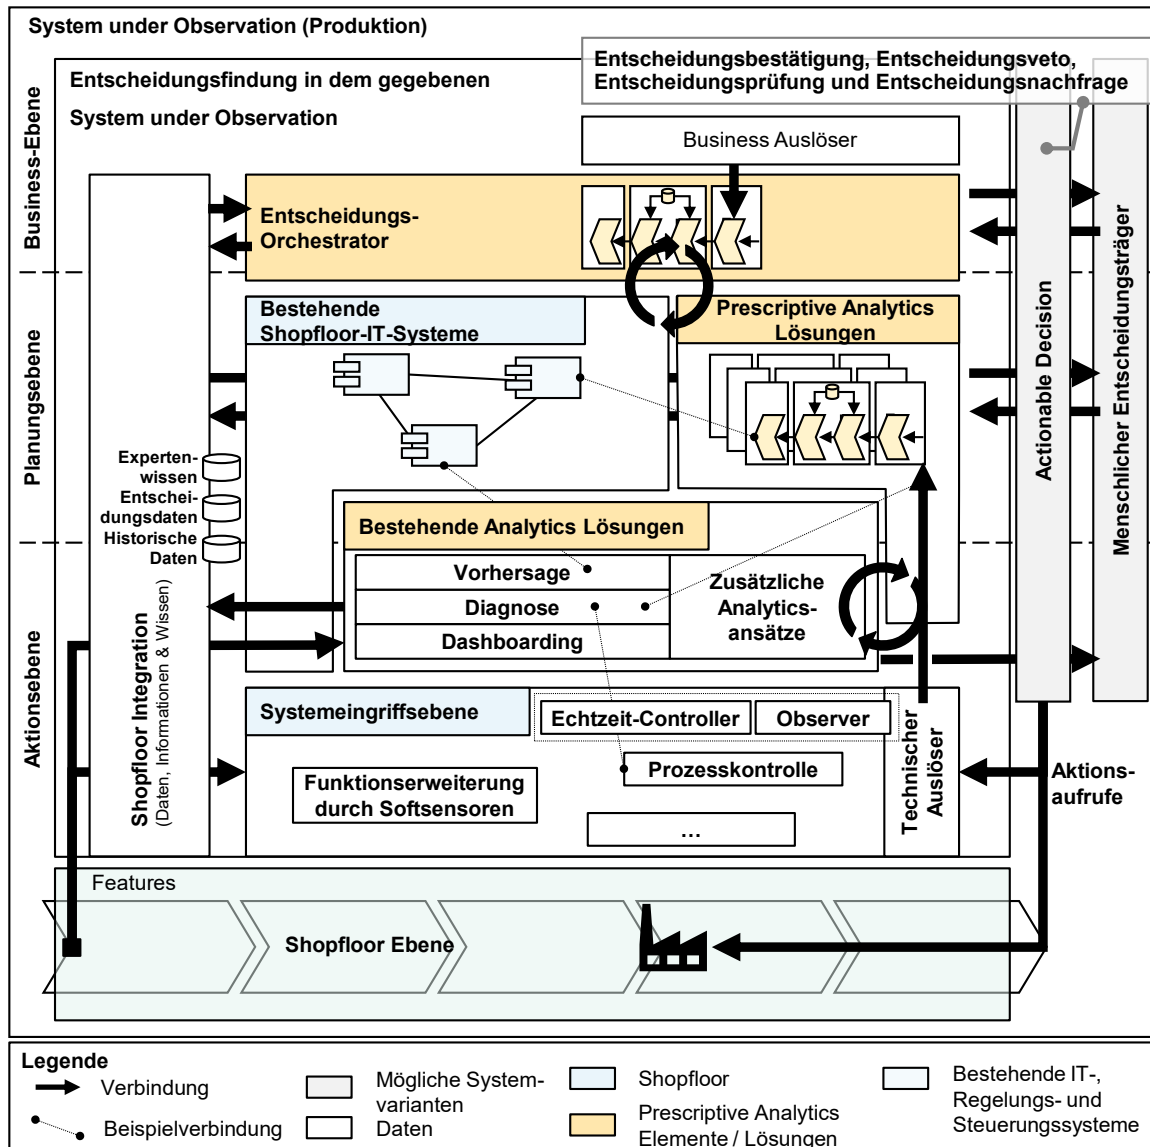


Bild 4-21: Referenzarchitektur zur Integration von Prescriptive Analytics

Die ausführliche Darstellung der **Referenzarchitektur zur Integration von Prescriptive Analytics Use Cases** beinhaltet die gleichen Schnittstellen und Elemente wie der konzeptionelle Überblick aus Bild 4-20. Lediglich die Elemente werden weiter ausdetailliert. Für die **bestehenden Analytics Lösungen** werden die Analytics Stufen nach GARTNER aus Kapitel 2.1.3 integriert. Die Datentöpfe der **Shopfloor Integration** basieren auf den möglichen Daten aus Kapitel 2.4.3. Die Ausgestaltung der Actionable Decision basiert auf den Stufen der hybriden Entscheidungsunterstützung aus Kapitel 2.4.2. Die Prescriptive Analytics Use Cases müssen nahtlos integriert werden, um Actionable Decisions zu ermöglichen. Dies erfordert immer einen kooperativen Ansatz mit dem menschlichen Entscheidungsträger.

Die Integration der Referenzpipeline für einzelne Prescriptive Analytics Use Cases wird als Baustein für einzelne Use Cases in dieser Architektur realisiert. Die Pipeline für den

**Entscheidungs-Orchestrator** und die **Prescriptive Analytics Lösungen** wird im Folgekapitel erläutert. Das Konzept der Entscheidungsinteraktion für den Entscheidungs-Orchestrator kann danach strukturiert werden, ob eine zentrale, dezentrale oder mehrstufige Entscheidungshierarchie entstehen soll. Dies ist abhängig von den Use Cases, die in der gegebenen Produktion existieren, und den IT-Systemen, die für die Verbindung zwischen den verschiedenen Entscheidungsinstanzen vorhanden sind. Als tiefgreifende Literatur wird auf Quellen zum Observer-Controller Ansatz aus dem Bereich der Mechatronik verwiesen (vgl. [BMM+06, DAG13, S. 113]).

Weiterhin führt die Abbildung drei Ebenen mit verschiedenen Zeithorizonten ein. Alle Ebenen entsprechen dem allgemeinen Verständnis von IT-Systemen auf der Grundlage der Automatisierungspyramide. Dieser Sachverhalt wird in der Referenzarchitektur in drei vertikale Level zusammengefasst (**Aktion, Planung, Business**). Diese begrenzen den zu betrachtenden Entscheidungsraum. In der Aktionsebene werden die Handlungsempfehlungen direkt umgesetzt. Die Planungsebene befasst sich auf einer höheren Abstraktionsebene mit den Prozessen der Produktion. Die Business-Ebene sammelt Input aus dem Umfeld des zu beobachtenden Systems.

#### 4.5.6 Referenzpipeline für Prescriptive Analytics Use Cases

Die Referenzpipeline kommt in **Phase vier** des übergeordneten Vorgehensmodells zur Anwendung (siehe Kapitel 4.3.3.4). Diese Phase beschreibt den Schritt der Aufbereitung zur Umsetzung eines Use Cases. Die **Referenzpipeline für Prescriptive Analytics Use Cases** dient als Referenz und Hilfestellung zur Modularisierung der relevanten Analytics Komponenten bei der Modellierung der Pipeline für die spätere Umsetzung. Sie wurde auf der *IEEE ADACIS* als [WMW+23] vorveröffentlicht. Die Referenzpipeline ist im Rahmen der Entwicklung der Referenzarchitektur im Kontext der Forschungsmethode nach GALSTER UND AVGERIOU entwickelt worden [GA11]. Eine detaillierte Beschreibung zur durchgeführten Forschung ist Anhang A3.3 zu entnehmen.

Die **Referenzpipeline** wird vom Analytics Architekten und Data Scientist verwendet. Sie dient als Blaupause für den Aufbau einer Verarbeitungspipeline (siehe Kapitel 4.2.1). Mögliche Ideen für eine Pipeline sollen in die gegebenen Felder eingetragen und verfeinert werden. Eine vereinfachte Darstellung ist in Bild 4-22 abgebildet.

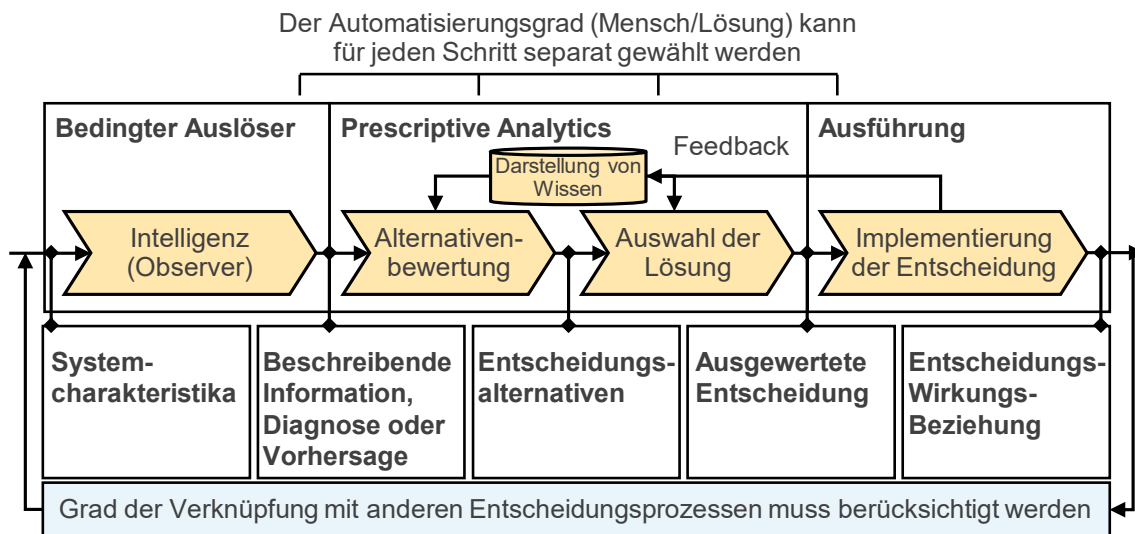


Bild 4-22: Referenzpipeline für Prescriptive Analytics Use Cases

Der Fokus der Referenzpipeline ist ein einzelner Use Case. Sie besteht aus den modularisierten Blöcken **bedingter Auslöser (Observer)**, **Prescriptive Analytics** und **Ausführung**. Je Block sind Input und Output Verbindungen definiert. Das Ergebnis des **bedingten Auslöserblocks** ist von entscheidender Bedeutung, da es die Grundlage für den Start einer Handlungsempfehlung durch die Pipeline bildet. Handlungsalternativen werden nur eruiert, wenn es dafür auch einen Auslöser gab. Die darin abgebildete **Intelligenz (Observer)** dient der Auslösung der Präskription. Dies unterstreicht die Tatsache, dass ein präskriptiver Algorithmus vom eigentlichen Auslöser getrennt werden kann. Der **Prescriptive Analytics Block** kann entweder durch deskriptive, diagnostische oder prädiktive Algorithmen mit Informationen und Daten bedient werden. Auf diese Weise wird Prescriptive Analytics mit dem Schwerpunkt auf Actionable Decisions ermöglicht. Der Schritt der Prescriptive Analytics ist in zwei Phasen unterteilt. Die erste Phase konzentriert sich auf die vorläufige **Alternativenbewertung** zur Handlungsempfehlung im gegebenen Zustandsraum. Aus den Alternativen wird in einer zweiten Phase, der **Auswahl der Lösung**, eine Entscheidung getroffen. Unterstützt werden beide Phasen durch eine Wissensrepräsentation. Die **Darstellung von Wissen** kann in Abhängigkeit der gewählten Implementierung variieren. Hierfür kann je nach Datentyp und -menge in der Wissensrepräsentation eine Graph-Datenbank, Tabellenrepräsentation oder die Verwendung eines Simulationsmodells sinnvoll sein. Es ist auch möglich, dass der Prescriptive Analytics Block durch eine End-to-End Lösung umgesetzt wird, die die Wissensrepräsentation und die beiden Phasen beinhaltet (vgl. Kapitel 2.4.2). Im Rahmen der lösungsneutralen Gestaltung kann die Phase inklusive Wissensrepräsentation somit auch durch ein Modell abgebildet sein. Mithilfe des **Ausführungsblocks** werden die Aktionen implementiert, die aus der Entscheidung folgen.

Der **Automatisierungsgrad** ist in Abhängigkeit vom Anwendungsfall zu wählen. Eine **Rückkopplungsschleife** ist möglich, um die Alternativen neu zu bewerten, wenn der Auswahlprozess keine geeignete Option findet. Entscheidungen, die auf kontinuierlichen

Ereignissen beruhen, können diskret behandelt werden, indem ein bedingter Trigger gesetzt wird, um Actionable Decisions nur bei Bedarf herbeizuführen (und neu zu bewerten). Die finale Ausgabe ist eine bewertete Actionable Decision. Eine optionale Rückkopplungsschleife zur Wissensrepräsentation kann genutzt werden, um ein lernendes System zu schaffen.

## 4.6 Werkzeugunterstützung

Zur Unterstützung von systematischen Vorgehensweisen in der Industrie ist eine **Werkzeugunterstützung** für die Umsetzung<sup>15</sup> unerlässlich [Bro25]. Ohne diese erfordert die Einführung der Spezifikationstechnik hohe initiale Aufwände (Einarbeitung, Pflege der Modelle, fehlende Schritt-für-Schritt Unterstützung). Das toolagnostische Konzept der Ausarbeitung kann von einer Reihe an IT-gestützten Hilfsmitteln (sogenannten Werkzeugen) unterstützt werden. Sie dienen primär der Erhöhung der Anwendbarkeit und Nutzerakzeptanz. Die Werkzeugunterstützung wird phasenübergreifend im Vorgehensmodell verwendet.

**Kapitel 4.6.1** gibt einen generellen Überblick über die Verwendung des IT-Werkzeugs *Archi* für die Modellierung. Analysefragen zur IT-gestützten Analyse der Modelle werden in **Kapitel 4.6.2** bereitgestellt. **Kapitel 4.6.3** ergänzt das IT-Tool um Workshopkarten für die Erarbeitung von Inhalten in Workshops.

### 4.6.1 Einordnung der Werkzeugunterstützung

Am Beispiel des Programms *Archi* wird die **Einordnung der Werkzeugunterstützung** in der Spezifikationstechnik durch ein Softwaretool (Werkzeug) beschrieben. *Archi* wurde aufgrund der einfachen Zugänglichkeit und der Marktdurchdringung des zugrundeliegenden Metamodells ausgewählt (vgl. [GAM24, S. 14]). Zum Konzept gehören Blaupausen für die Partialmodelle, die Spezialisierung des Metamodells sowie eine Anpassung des Farbschemas. Aufgrund der Offenheit der Spezialisierung des Metamodells können andere Werkzeuge wie *LeanIX* eingesetzt werden. Ein Mapping der Spezialisierung auf weitere Metamodelle (z. B. von *LeanIX*) kann dem Anhang entnommen werden (siehe Anhang A2.7). Die Überführung des Lösungskonzepts in ein werkzeuggestütztes Modellierungskonzept ergibt eine Reihe an Vorteilen:

- Verringerung von Aufwänden im Prozess der Konzeption
- Rückverfolgbarkeit von Design-Entscheidungen
- Erhöhen der allgemeinen Ergebnisqualität bei der Konzeption
- Komplexitätsmanagement und Kooperation (Verbesserung der Zugänglichkeit)

---

<sup>15</sup>In der Quelle bezieht sich diese Aussage auf das Vorgehen im Rahmen des Artefakts einer Systematik. Da eine Spezifikationstechnik eine Systematik beinhaltet, lässt sich diese Aussage auf den vorliegenden Kontext übertragen.

Das Fehlen dedizierter Werkzeuge für die Governance von KI und Analytics Lösungen auf dem Shopfloor stellt eine ungelöste Herausforderung für die Praxis dar [McC24]. Aus diesem Grund wird das Konzept zwar am Beispiel *Archi* (eigentlich primär für EAM-Modelle konzipiert) demonstriert, jedoch werkzeugunabhängig entworfen. Ein Einblick in die Nutzeroberfläche in *Archi* ist in Bild 4-23 dargestellt.

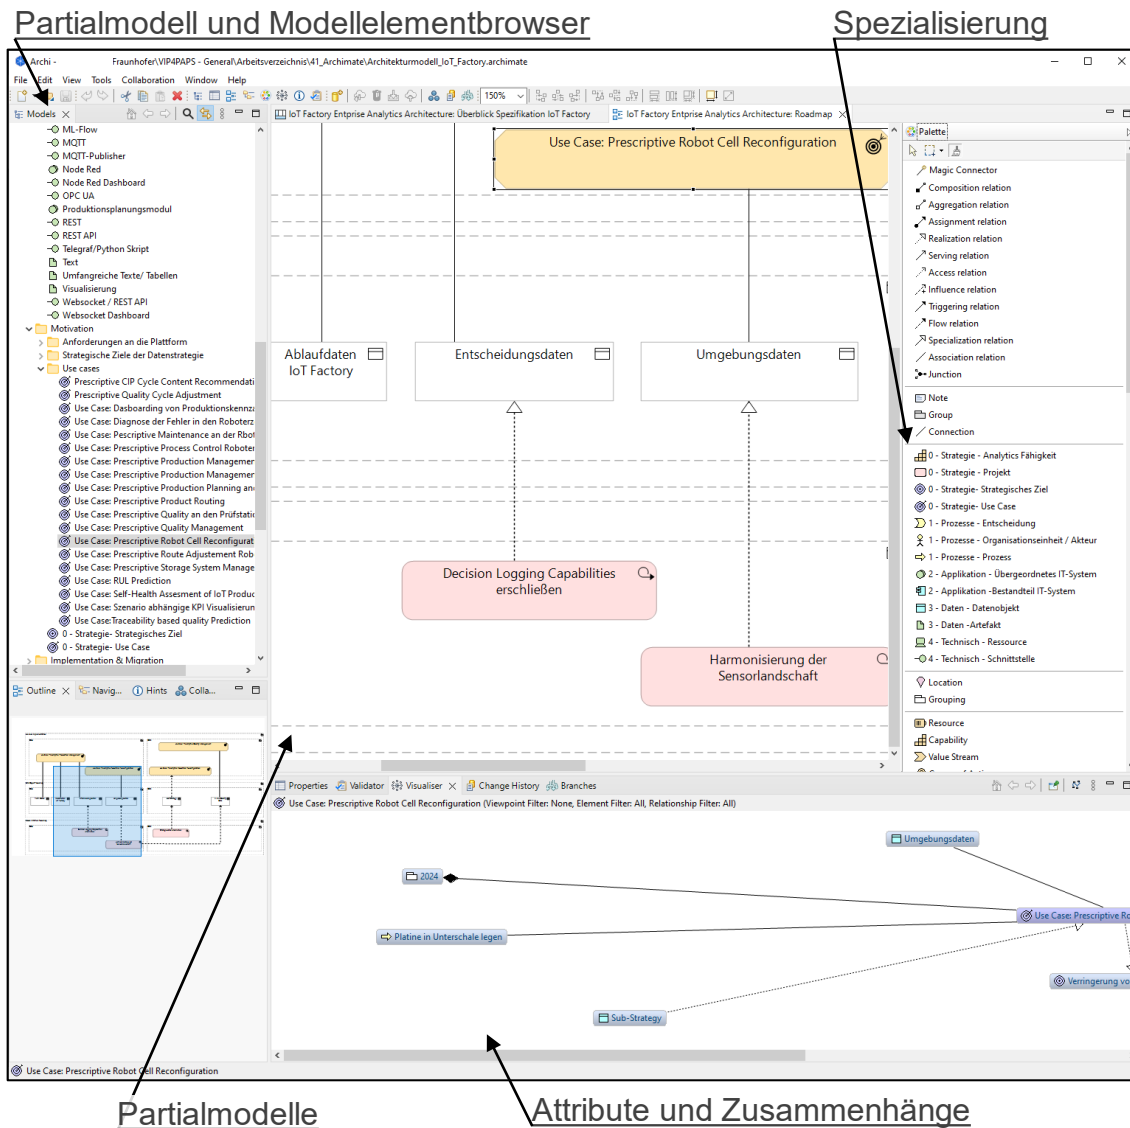


Bild 4-23: Nutzeroberfläche des Werkzeugs Archi mit der gewählten Spezialisierung des Metamodells ArchiMate der Spezifikationstechnik

Die verwendbaren Modellierungselemente werden in der linken Menüleiste im **Partialmodell-** und **Modellelementbrowser** dargestellt. Im selben Reiter ist ein Modellüberblick verfügbar. Die untere Leiste dient der nutzerbezogenen Anzeige von Informationen (z. B. Attribute, Verbindungen). Weiterhin sind Funktionen wie ein Konsistenzcheck im Werkzeug integriert. In der Mitte des Bildes werden das aktuell ausgewählte **Partialmodell** oder erzeugte Sichten im gewählten Vergrößerungsgrad und Ausschnitt visualisiert.

Auf der rechten Seite ist ein direkter Zugriff auf die **Spezialisierung** möglich. Im unteren Bereich des Bildes sind **Attribute** und automatisiert visualisierte **Zusammenhänge** der Modellelemente ersichtlich. Neben dem einfachen Export von Bildern bietet sich der Export einer interaktiven, aber nicht veränderbaren Ansicht in Form des *html* Formats an.

#### 4.6.2 Analysefragen zur Synergie- und Schnittstellenbetrachtung

Ergänzend werden **Analysefragen zur Synergie- und Schnittstellenbetrachtung** im Programm *Archi* bereitgestellt. Das Aufdecken von Synergien zwischen verschiedenen Use Cases kann Implementierungs- und Instandhaltungskosten für die umgesetzten Lösungen senken [SvS+24, S. 170]. Dies kann zum Beispiel durch die Implementierung von Standardfunktionen erreicht werden [SvS+24, S. 173]. Daher bietet es sich an, basierend auf dem Modell mögliche Synergien und Schnittstellen zwischen einzelnen Use Cases zu ermitteln. Die Analysefragen wurden im Rahmen der Ausarbeitung mithilfe des Brainstorming Vorgehens nach Wilson [Wil13] initial erarbeitet. Zur Strukturierung der Analysefragen wird auf dem Vorschlag nach STUHT aufgebaut. Der Ansatz nach STUHT beschäftigt sich allgemein mit Unternehmensarchitekturen. Ein Teil dieses Ansatzes wird für den Bereich der Prescriptive Analytics Use Cases in der Produktion instanziiert [Stu18, S. 45].

Es werden Analysefragen als Leitfragen und Hilfestellung zur Ermittlung von Schnittstellen und Synergien zwischen den einzelnen Use Cases vorgeschlagen. Diese entfalten ihren Nutzen beim Einsatz in verteilten oder größeren Teams mit mehreren Analytics Architekten und Data Scientists. Weiterhin können sie für die Umsetzung eines kontinuierlichen Verbesserungsprozesses und einer kontinuierlichen Analytics Architektur-Analyse genutzt werden. Die Leitfragen wurden im Rahmen der Entwicklung mehrfach (Designzyklen) iterativ angepasst. Hauptfokus der Analysefragen ist die Unterstützung der Analyse des Modells über alle Partialmodelle hinweg. Es folgt ein zweistufiges Konzept. Dieses unterscheidet zwischen der **direkten Analyse des Architekturmodells** und der **Nutzung des Architekturmodells als Informationsbasis**<sup>16</sup>. Ein Überblick über alle Kategorien für Analysefragen ist in Bild 4-24 dargestellt.

---

<sup>16</sup>Die Fragen wurden im Rahmen einer Masterarbeit technisch umgesetzt. Die Zugänglichkeit wird durch die Nutzung von generativer KI zur Suchabfrageunterstützung erhöht. Die Ergebnisse der Masterarbeit sind kein Teil dieser Ausarbeitung. Es wird verwiesen auf die Masterarbeit mit dem Titel „Framework for the Generative AI enabled Analysis of EAM based Analytics Use Case Models in Smart Factories“.

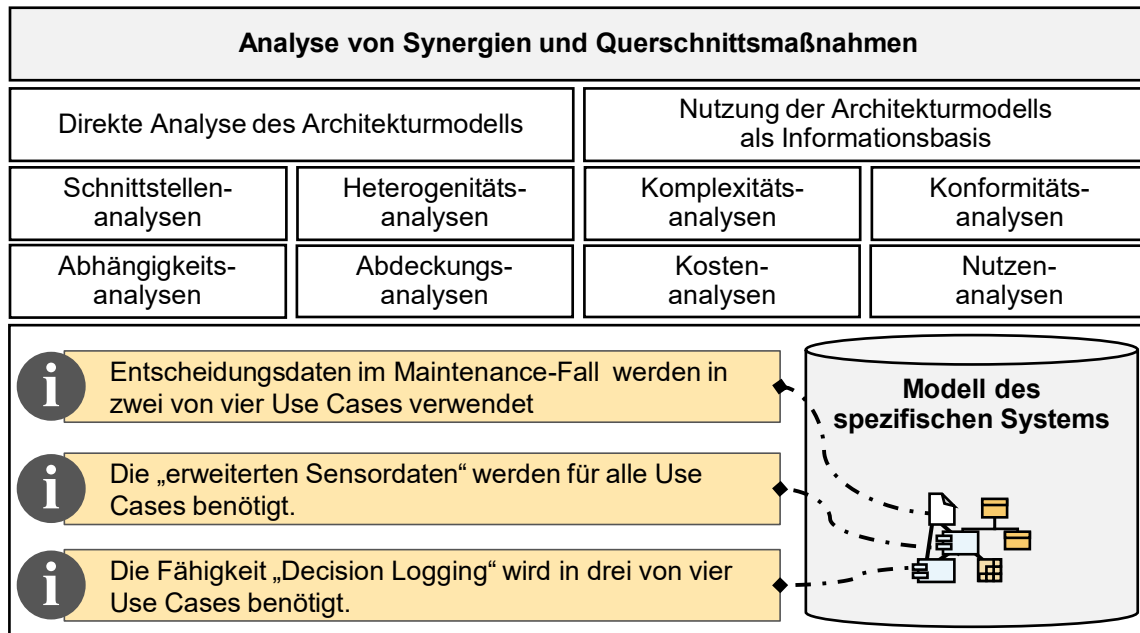


Bild 4-24: Leitfragen für die Analyse von Schnittstellen zwischen den verschiedenen Use Case Konzepten (aufbauend auf [Stu18, S. 45])

Beispielskripte zur technischen Umsetzung der **Analyse von Synergien und Querschnittsmaßnahmen** in *Archi* wurden im Rahmen der Ausarbeitung umgesetzt. Abfragen je Kategorie sind beispielhaft im Anhang visualisiert (siehe Anhang A2.11). Nachfolgend werden Beispiele für Analysefragen gegeben:

- **Schnittstellenanalysen:** Ineffizienzen im Prozess der Use Case Entwicklung entstehen durch nicht freigesetzte Synergiepotenziale zwischen Analytics Lösungen [SvS+24, S. 173, De16, S. 28]. Zur Minderung dieses Umstands wird die Frage „Welche Datenbanken müssen für die gewählten Use Cases neu implementiert werden?“ oder „Welche Capabilities werden in mehreren Use Cases beeinflusst?“ bereitgestellt.
- **Konformitätsanalysen:** Zur Unterstützung der Korrektheit der Modellierung können Analysefragen wie „Sind alle Daten aus den Use Cases bereits Teil des Datenkatalogs?“ oder „Sind alle fehlenden Objekte eines Use Cases als Projektteile in der Roadmap hinterlegt?“ gestellt werden. Die semantischen Fragen bieten ein hohes Potenzial für eine zumindest teilautomatisierte Unterstützung bei der Bearbeitung.
- **Kostenanalysen:** Aufwände in der Industrial Data Science sind insbesondere in der Datenakquise und -bereitstellung (bei benötigter Anzahl und Qualität) hoch [HWS+19, S. 406]. Um diesem Umstand zu begegnen, wird die Analysefrage „Welche Use Cases nutzen die gleichen Datenobjekte?“ bereitgestellt.

### 4.6.3 Unterstützung durch Workshopkarten

Wie in Kapitel 4.4 motiviert, eignen sich Workshops zur Erarbeitung von Inhalten für die Partialmodelle. Dafür werden durch die Spezifikationstechnik Workshopkarten zur Verfügung gestellt. Diese dienen der papierbasierten Erarbeitung von Inhalten mit einem interdisziplinären Teilnehmerkreis. Die Ergebnisse können im Nachgang digitalisiert und in ein IT-Werkzeugen übertragen werden. Die Workshopkarten können direkt den Spezialisierungen des Metamodells zugeordnet werden (Zusammenhang vgl. Bild 4-25). Die Erläuterung der Bedeutung der Workshopkarten wird in Anhang A2.6 dargestellt.

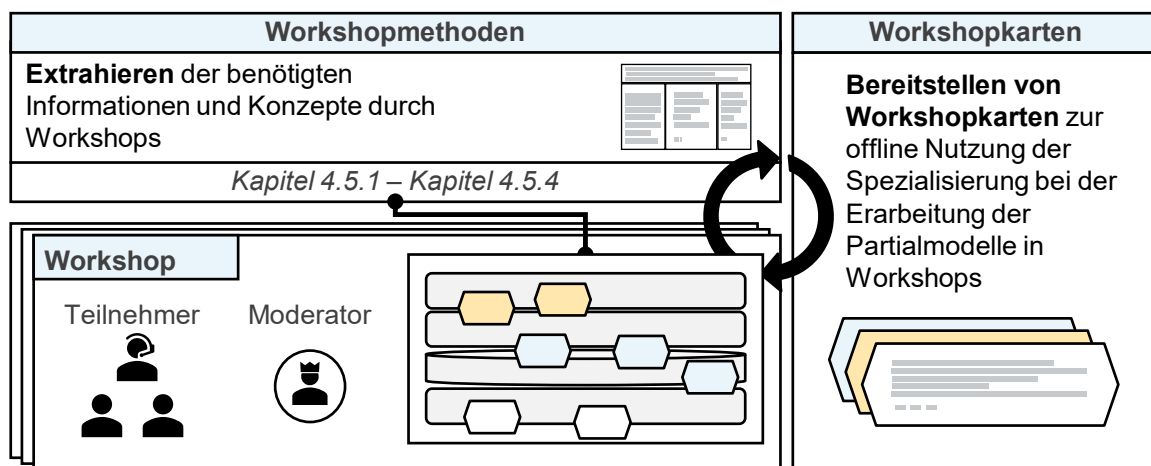


Bild 4-25: Übersicht über die Verwendung der Workshopkarten im Workshop

Die in Kapitel 4.5 vorgestellten **Workshopmethoden** werden durch **Workshopkarten** unterstützt. Diese dienen der Standardisierung der Durchführung der moderierten **Workshops**. Die Workshops dienen der iterativen Erarbeitung der Inhalte des Modellierungskonzepts der Spezifikationstechnik.



## 5 Demonstration und Evaluation der Spezifikationstechnik

Das Kapitel 5 dient der durchgängigen **Demonstration und Evaluation** der *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* an einem Anwendungsbeispiel. Instanzierte Detailsichten einzelner Bestandteile der Spezifikationstechnik sind zum Zwecke der Übersichtlichkeit im Anhang beigelegt (siehe Kapitel A3).

Die Gegebenheiten im Anwendungsbeispiel der IoT Factory Gütersloh werden in **Kapitel 5.1** dargestellt. Darauf aufbauend wird die Demonstration der Spezifikationstechnik am Beispiel der IoT Factory Gütersloh beschrieben. Dadurch wird die Funktionstauglichkeit gezeigt. Nur die relevanten Ergebnisse der einzelnen Phasen werden präsentiert. In der Evaluation in **Kapitel 5.2** wird die Spezifikationstechnik mit den Anforderungen aus der Problemanalyse verglichen und es werden Evaluationsinterviews zur Überprüfung der Nutzbarkeitsaspekte der Spezifikationstechnik beschrieben. Darauf basierend werden in **Kapitel 5.3** die Ergebnisse der Evaluation des Gesamtartefakts der Spezifikationstechnik diskutiert. Im Rahmen der Ausarbeitung wird nur auf die finalen Partialmodelle eingegangen.

### 5.1 Demonstration anhand eines Anwendungsbeispiels

Die Demonstration der Spezifikationstechnik erfolgt im Rahmen des *VIP4PAPS* Projektes. Übergeordnetes Ziel des *VIP4PAPS* Projektes ist die Erarbeitung einer Prescriptive Analytics Plattform für die Produktion. Teil des Projektes ist die Erarbeitung mehrerer Prescriptive Analytics Use Cases basierend auf den Vorarbeiten in der **IoT Factory Gütersloh** (ergänzende Beschreibungen vgl. [HSB24-01]). Auf der linken Seite in Bild 5-1 ist die IoT Factory Gütersloh abgebildet. Die rechte Seite in Bild 5-1 zeigt das IoT Device, welches in der IoT Factory Gütersloh hergestellt wird.




Bild 5-1: Überblick über die IoT Factory Gütersloh sowie das IoT Device [HSB24-01]

Die **IoT Factory Gütersloh**<sup>17</sup> eignet sich im besonderen Maße zur Demonstration der Spezifikationstechnik<sup>18</sup>. Die IoT Factory besteht aus 19 Produktionsstationen, mit denen IoT Produkte in einem kontinuierlichen Zyklus hergestellt werden. Eine Demontage der produzierten Produkte ist zusätzlich auf den gleichen Stationen möglich. Zu den Stationen gehören fünf Roboterzellen, drei Qualitätskontrollstationen, ein externes und ein internes Lager sowie eine Flotte von vier fahrerlosen Transportfahrzeugen. Jede Station ist mit Sensoren ausgestattet. Dazu zählen z. B. Kraft- und Drehmomentsensoren am Roboterarm, Beschleunigungssensoren, Lasersensoren an den fahrerlosen Transportfahrzeugen und Leistungsmesser an den Förderbändern. Darüber hinaus ist jedes produzierte **IoT Device** (vgl. rechte Seite Bild 5-1) mit mehreren Sensoren ausgestattet, um seinen Zustand (z. B. Qualitätsdaten) während des Montage- und Demontageprozesses zu charakterisieren. Weiterhin gibt es eine ausreichende Menge an Vorarbeiten, die es erlauben, komplexere Analytics Use Cases anzugehen. Zur teilweisen Parallelisierung des Prototypings und der Konzeption (siehe Kapitel 4.3.3.2) wird eine Entwicklung eines Prototyps bei der Anwendung der ausgewählten Use Cases parallel vorangetrieben. Dies dient primär der Demonstration der technischen Machbarkeit der angestrebten Prescriptive Analytics Lösungen. Eine Einschränkung bei der Demonstration liegt einzig bei der Abbildung der geforderten Rollen vor. Die Rollen des Analytics Architekten, Industrie 4.0 Managers, Data Scientists und Produktionsexperten werden im Rahmen des Projektes von einem kleineren Personenkreis als in der Zielgruppe in einem Produktionsumfeld üblich abgebildet.

Nachfolgend werden die Phasen des Vorgehensmodells aus Kapitel 4.3 in **Kapitel 5.1.1 bis Kapitel 5.1.4** anhand des durchgehenden Anwendungsbeispiels der IoT Factory durchlaufen. Für die Phasen eins und drei wird jeweils auf alle Use Cases in der IoT Factory eingegangen. Phase zwei und vier werden exemplarisch anhand eines der Prescriptive Analytics Use Cases in der IoT Factory erläutert. Es kommen das Modellierungskonzept (siehe Kapitel 4.4) sowie die relevanten Artefakte zur Unterstützung zum Einsatz (siehe Kapitel 4.5). Ergänzt wird die Spezifikation durch die Anwendung der Werkzeugunterstützung (siehe Kapitel 4.6).

### 5.1.1 Strategische Planung der Use Cases

Die **strategische Planung der Use Cases** umfasst die Punkte der Standortbestimmung, Use Case Ideation, Use Case Transformation und Use Case Priorisierung. Eingangsgrößen der Phase eins sind vorhandene Vorarbeiten zur Erfassung des Ist-Standes und Strategien aus dem relevanten Bereich der Analytics Strategie. Die Phase wird vom Industrie 4.0 Manager geleitet. Der Analytics Architekt wird unterstützend hinzugezogen.

---

<sup>17</sup> Im Folgenden: IoT Factory

<sup>18</sup> Eine Instanziierung der Spezifikationstechnik wurde in einem Auftragsforschungsprojekt angewandt (Einsatz von Prescriptive Analytics für den Maschinen- und Anlagenservice in der Produktion). Der Vollständigkeit und Übersichtlichkeit halber wird auf das Beispiel der IoT Factory zurückgegriffen.

Die Partialmodelle des Use Case Portfolios und der Capability Map für Prescriptive Analytics werden gefüllt. Verwendet wird dafür die Prescriptive Analytics Use Case Transformation Canvas und die generische Prescriptive Analytics Capability Map sowie die Aufwand-Nutzen-Bewertung. Der relevante Schritt aus dem übergeordneten Vorgehen ist in Bild 5-2 dargestellt.




Bild 5-2: Phase eins des übergeordneten Vorgehensmodells

Das **Kernergebnis** der Phase ist ein **priorisiertes Use Case Portfolio**. Ein Überblick über die Demonstration des Schrittes der strategischen Planung der Use Cases in der IoT Factory ist Bild 5-3 zu entnehmen. Im Übersichtsbild werden die relevanten Phasen, die verwendeten Artefakte (ausschnittsweise) sowie deren logische Zusammenhänge dargestellt.

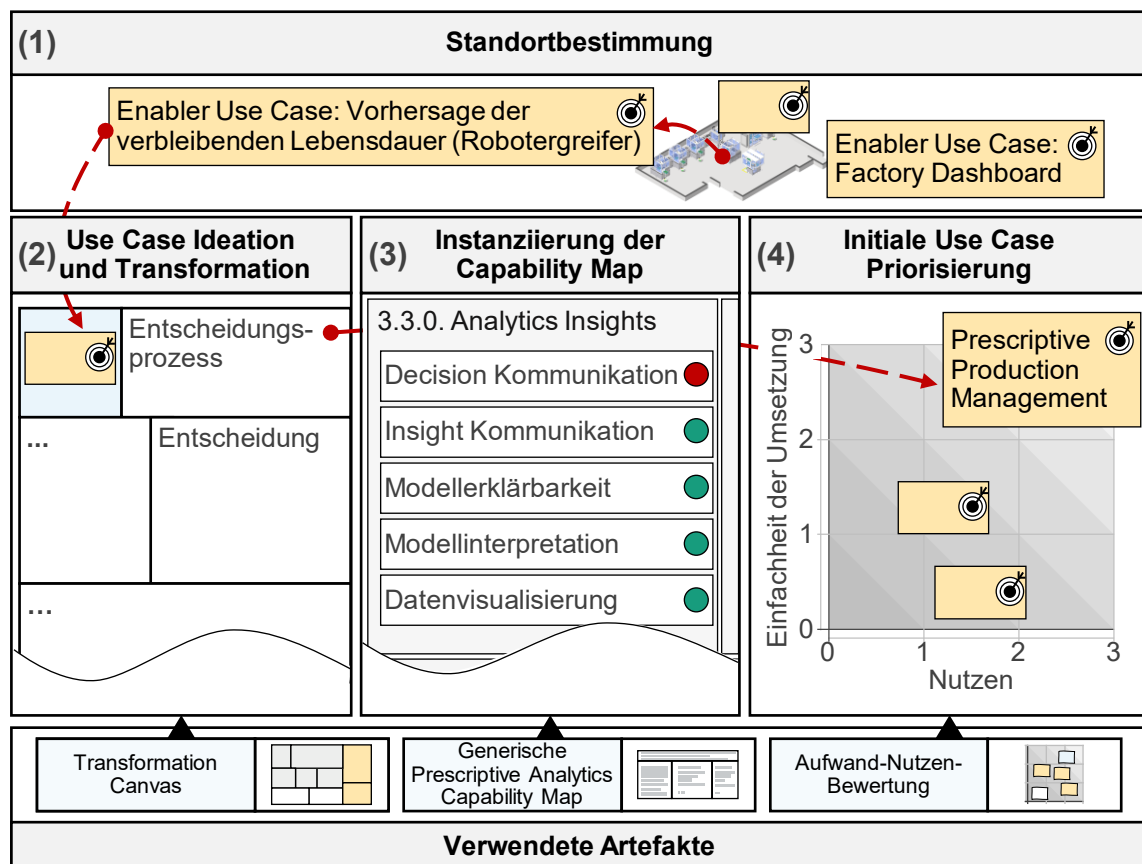


Bild 5-3: Phase eins - Zusammenhänge bei der Ausdetaillierung der relevanten Inhalte zur Erzeugung des initial priorisierten Use Case Portfolios

## Standortbestimmung

Vorhandene Substrategien und strategische Ziele für den Bereich der IoT Factory existieren vorab außerhalb einer groben Zielformulierung nicht. Zur Aufnahme der strategischen Ziele wird ein Workshop mit allen relevanten Stakeholdern der IoT Factory auf Managementebene durchgeführt. Sonstige relevante Vorarbeiten (siehe Kapitel 4.3.3.1) werden im Rahmen der **Standortbestimmung** zusammengetragen. Dazu zählen die vorhandenen Dokumentationen von Unternehmensprozessen (keine), die Applikationsarchitektur (rudimentär), Informationsarchitektur (keine) und technische Architektur (detailliert). Es existiert ein Materialflusssimulationsmodell der IoT Factory. Insbesondere die fehlende Dokumentation zu vorhandenen Daten und der Dateninfrastruktur sorgen für eine fehlende Transparenz über mögliche Hemmnisse und Herausforderungen bei der Umsetzung weiterer Use Cases. Folgende Analytics Use Cases wurden bereits vorab umgesetzt:

- **IoT Factory Dashboard:** Dieser Descriptive Analytics Use Case sammelt relevante Kennzahlen und Daten in einer Visualisierung nahe der Roboterzellen. Das Dashboard dient der Überwachung der Produktionskennzahlen.
- **RUL-Prediction** (Remaining Useful Lifetime) eines Robotergreifers: Die RUL-Prediction schätzt den wahrscheinlichen Zeitpunkt vorab, wann der Robotergreifer ausfallen wird. Dies baut auf einer zuvor durchgeführten Anomalie-Detektion auf und ist online-fähig.
- **Vernetzung der IoT Factory Daten:** Daten aus allen Maschinen, dem MES und von den fahrerlosen Transportfahrzeugen sind bereits verfügbar und vernetzt.
- **Audio-basierte Predictive Quality:** Der Qualitätszustand der hergestellten IoT Devices wird mittels Mikrofondaten und einer auf neuronalen Netzen basierenden Vorhersage bewertet.

## Use Case Ideation und Transformation

Folgend werden basierend auf der Standortbestimmung mögliche Prescriptive Analytics Use Case Ideen entworfen (**Ideation**), konkretisiert und priorisiert. In Form eines Workshops wird je Use Case die Prescriptive **Analytics Use Case Transformation Canvas** ausgefüllt. Ein Ausschnitt aus der bearbeiteten Canvas ist in Bild 5-4 dargestellt. Für die vollständige Version wird auf Anhang A4.1 verwiesen.

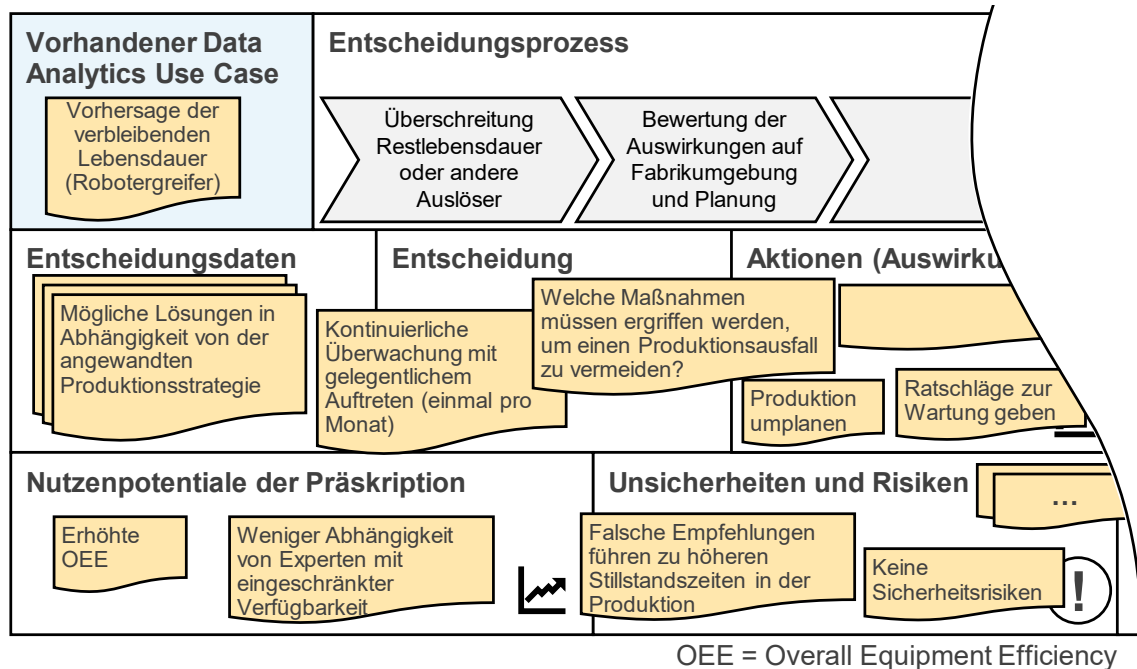


Bild 5-4: Ausgefüllte Prescriptive Analytics Use Case Transformation Canvas

Der **vorhandene Analytics Use Case**, auf dem aufgebaut wird, ist die Vorhersage der verbleibenden Restlebensdauer des Robotergreifers. Im Falle des Prescriptive Production Managements wird eine **Entscheidung** im **Entscheidungsprozess** durch verschiedene Auslöser ausgelöst. Dazu zählt etwa das Unterschreiten der zulässigen Restlebensdauer (RUL-Prediction). Zugrundeliegende **Entscheidungsdaten** sind zum Beispiel die bisher dokumentierten Lösungsansätze bei Ausfällen. **Aktionen** können die Umplanung der Produktion oder die Unterstützung bei ungeplanten Wartungen sein. Eine mögliche **Unsicherheit** und ein **Risiko** bei den Empfehlungen sind beispielsweise Produktionsausfälle durch falsche Empfehlungen. **Nutzenpotenziale** werden vor allem in der Erhöhung der OEE gesehen. Essenziell für die weitere Konzeption ist die Definition eines initialen Zielautomatisierungsgrades. Es wird sich auf ein Audit-System fokussiert (siehe Kapitel 2.4.1). Das Ergebnis dient als Input für die Priorisierung der Use Cases im Portfolio.

### Instanziierung der Capability Map

Im nächsten Schritt wird die generische Prescriptive Analytics **Capability Map** eingesetzt (siehe Kapitel 4.5.3). Sie wird für den Anwendungskontext **instanziiert**. Nach der Instanziierung wird eine Bewertung der IoT Factory durchgeführt. Ein Auszug der Bewertung ist in Bild 5-5 dargestellt.

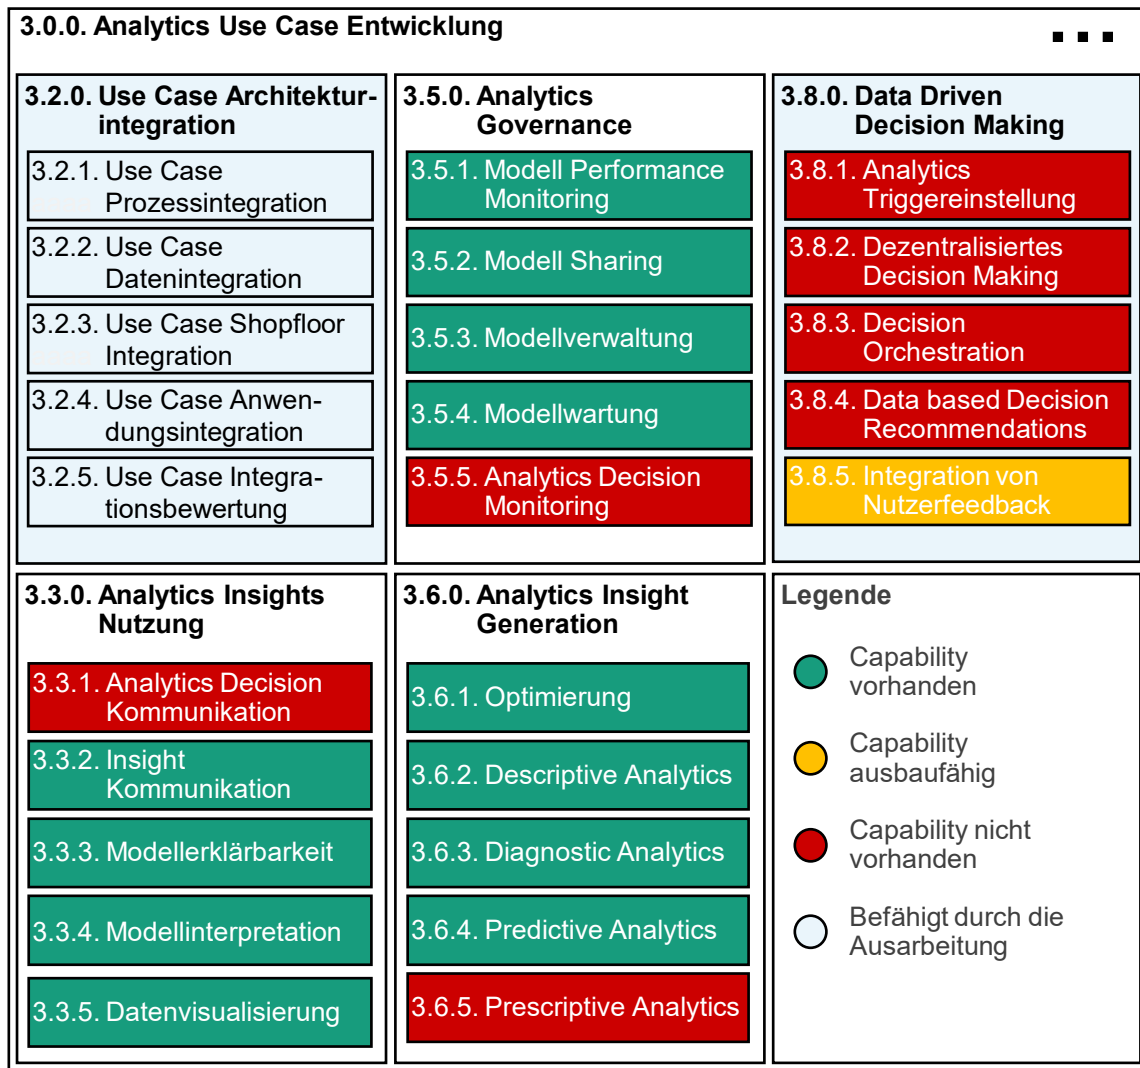


Bild 5-5: Ausschnitt der instanziierten Capability Map für Prescriptive Analytics

Im Workshop wird zweistufig vorgegangen. Zuerst werden die für die IoT Factory relevanten Capabilities bei der **Analytics Use Case Entwicklung** identifiziert. In einem zweiten Schritt wird jede Capability einzeln bewertet. Abschließend wird das Ergebnis diskutiert. Die Standortbestimmung wird dabei durch folgende Erkenntnisse ergänzt: Capabilities zur ganzheitlichen **Use Case Architekturintegration** sind nicht in besonderem Maße ausgeprägt. Dies liegt unter anderem daran, dass Use Cases bisher opportunitätsbasiert umgesetzt wurden. Allgemein liegt in der IoT Factory ein hoher Reifegrad bei den Capabilities der **Analytics Governance**, der **Analytics Insight Generation** und **Analytics Insight Nutzung** vor. Für **Prescriptive Analytics** und **Data Driven Decision Making** ist keine der relevanten Capabilities in der Organisation der IoT Factory vorhanden. Eine Übersicht über die vollständige Bewertung aller Level drei Capabilities ist dem Anhang zu entnehmen (siehe Anhang A4.2).

## Initiale Use Case Priorisierung

Die aus der Prescriptive Analytics Use Case Transformation Canvas stammenden Use Cases werden gesammelt und **initial priorisiert** (vgl. Bild 5-6). Ergänzt werden diese um Befähiger Use Cases. Ein Beispiel ist die automatisierte Extraktion von Expertenwissen aus Dokumenten. Dies stellt im Kern keinen Prescriptive Analytics Use Case dar, dient aber als Grundvoraussetzung für das benötigte Expertenwissen für den Prescriptive Production Management Use Case. Diverse Autoren schlagen zur Bewertung von Industrie 4.0 Use Cases und Analytics Use Cases die Verwendung eines Portfolios zur Aufwand-Nutzen-Bewertung vor (vgl. [KML+19, ENM+20, GKD23]). Im Fall der Auswahl von Prescriptive Analytics Use Cases bieten sich die Achsen „**Einfachheit der Umsetzung**“ und „**Nutzen**“ an. Zur Priorisierung werden alle Use Case Ideen gesammelt, nach Aufwand und Nutzen bewertet und in ein **Portfolio** relativ zueinander eingeordnet.

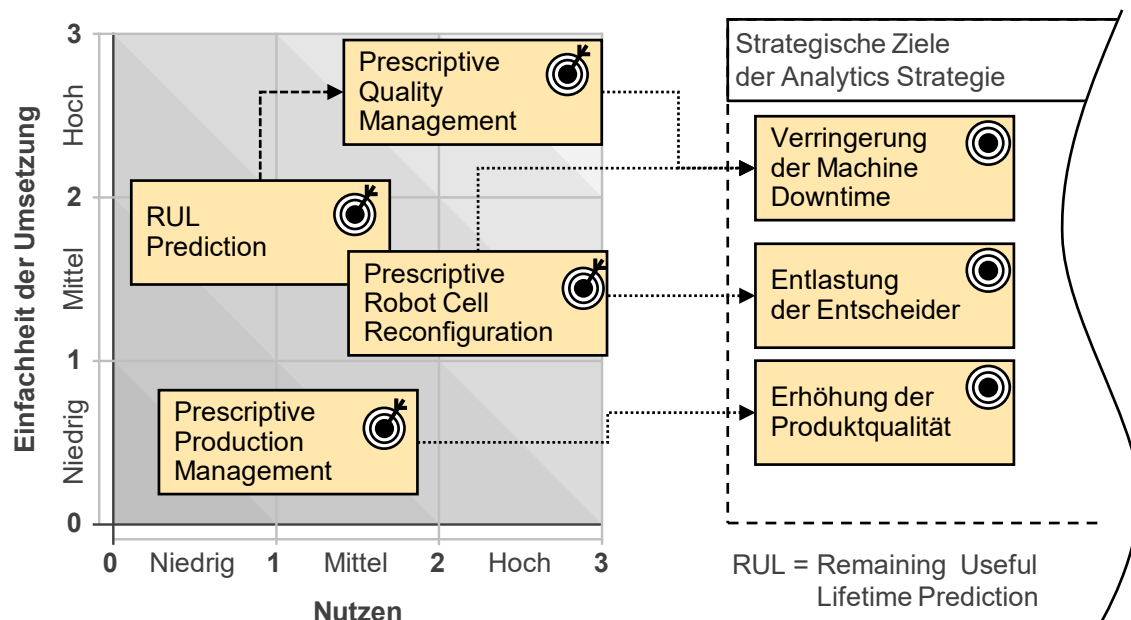


Bild 5-6: *Initiale Bewertung der Prescriptive Analytics Use Cases in der IoT Factory*

Es werden drei **Use Cases** zur Konzeption und Umsetzung ausgewählt. Die Beschränkung auf drei Use Cases begründet sich in der Abschätzung des benötigten Aufwandes bei vorliegenden Ressourcen zur Umsetzung der spezifizierten Ergebnisse der Spezifikationstechnik. Die Use Cases wurden mit den **strategischen Zielen** der IoT Factory in Verbindung gebracht. Im Anhang A4.3 wird separat auf die Erkenntnisse der Aufwand-Nutzen-Abschätzung eingegangen. Weitere Use Cases im Backlog können zur Erweiterung herangezogen werden:

- **Prescriptive Production Management:** Kern des Use Cases ist die Entscheidungsunterstützung im operativen Geschehen bei unvorhergesehenen Ereignissen in der Produktion. Der Use Case baut auf der **RUL-Prediction** auf. Es werden verschiedene Wissensquellen formalisiert und so möglichst viel Expertenwissen angesammelt. Während der Produktion werden die Daten des MES aufgezeichnet

und mit vorhandenen Dokumenten kombiniert. Übergeordnetes Ziel ist die Empfehlung von Reaktionsstrategien bei Ausfällen oder Störungen im Rahmen der Produktion. Es müssen Entscheidungen getroffen werden, falls ein möglicher Systemausfall vorhergesagt wird. Einige beispielhafte Fehler werden im Folgenden aufgeführt. Es kann auftreten, dass der Greifer das Produkt aufgrund einer Verformung des Greifers oder des Produkts nicht mehr richtig greifen kann. Die Montagestation oder die Förderbänder können bereits belegt sein oder verschiedene Sensoren erkennen, dass ein Mitarbeiter eine manuelle Aufgabe ausführt, die nicht Teil der automatisierten Produktionslinie ist.

- **Prescriptive Quality Management:** Der zweite Use Case bezieht sich auf das Qualitätsmanagement (Produkt) und hat zum Ziel auf Qualitätsabweichungen direkt zu reagieren. Er baut primär auf den vernetzten IoT Daten auf. Zum Zeitpunkt der Veröffentlichung befanden sich die Ergebnisse des Use Cases in der Validierung. Prescriptive Analytics wird verwendet, um Maßnahmen zu empfehlen, die die Qualität der fertigen Produkte sicherstellen. Beispiele sind eine manuelle Sichtprüfung oder die Anpassung von Prozessparametern auf definierte Einstellwerte.
- **Prescriptive Robot Cell Configuration:** Kern des dritten Use Cases ist die Erzeugung einer Fehlererkennung (Diagnose) im Roboter Greifprozess der Montage. Diese Diagnose soll direkt verknüpft werden mit möglichen Handlungsempfehlungen, je nachdem welche Abweichung vom Normalzustand im Produktionsablauf erkannt wird.

### 5.1.2 Konzeption der ausgewählten Use Cases

Der Schritt der **Konzeption der ausgewählten Use Cases** wird für den Use Case „Prescriptive Production Management“ erläutert. Die anderen Use Cases werden parallel konzeptioniert. Es werden Konzepte erarbeitet und formalisiert, wie mit dem Prescriptive Production Management Use Case interagiert wird, welche Architektur dafür benötigt wird und welche Daten im Use Case besonders wichtig sind. Übergeordnetes Ziel der Phase zwei ist die Konzeption der ausgewählten Prescriptive Analytics Use Cases. Der Ablauf ist für alle ausgewählten Use Cases gleich. Unter Anleitung des Analytics Architekten werden die jeweiligen Partialmodelle über die zur Verfügung gestellten Artefakte gefüllt.

Die Partialmodelle zur Integration werden als Referenz und zum Prozessverständnis genutzt. Fehlende Partialmodelle werden nachmodelliert. Im Rahmen der IoT Factory fehlt die Darstellung der Prozesse. Diese wurden mit der **Workshopmethode** der Data Map (detaillierte Darstellung siehe Anhang A4.4) mit dem Analytics Architekten und den Prozessverantwortlichen aufgenommen. Weiterhin werden in der Konzeption schrittweise alle Partialmodelle der Perspektive der Konzeption (außer Use Case Pipeline) gefüllt. Dafür werden die Analytics Canvas (siehe Kapitel 3.2.2) sowie die Prescriptive Analytics

Data Canvas genutzt. Hierfür zieht der Analytics Architekt den Data Scientist hinzu. Der relevante Schritt aus dem übergeordneten Vorgehen ist in Bild 5-7 dargestellt.




Bild 5-7: Phase zwei des übergeordneten Vorgehensmodells

Das Kernergebnis der Phase sind Prescriptive Analytics Use Case Konzepte für die IoT Factory. Ein Überblick über den Schritt der Konzeption wird in Bild 5-8 gezeigt. Im Übersichtsbild werden die relevanten Phasen, die verwendeten Artefakte (ausschnittsweise) sowie deren logische Zusammenhänge dargestellt.

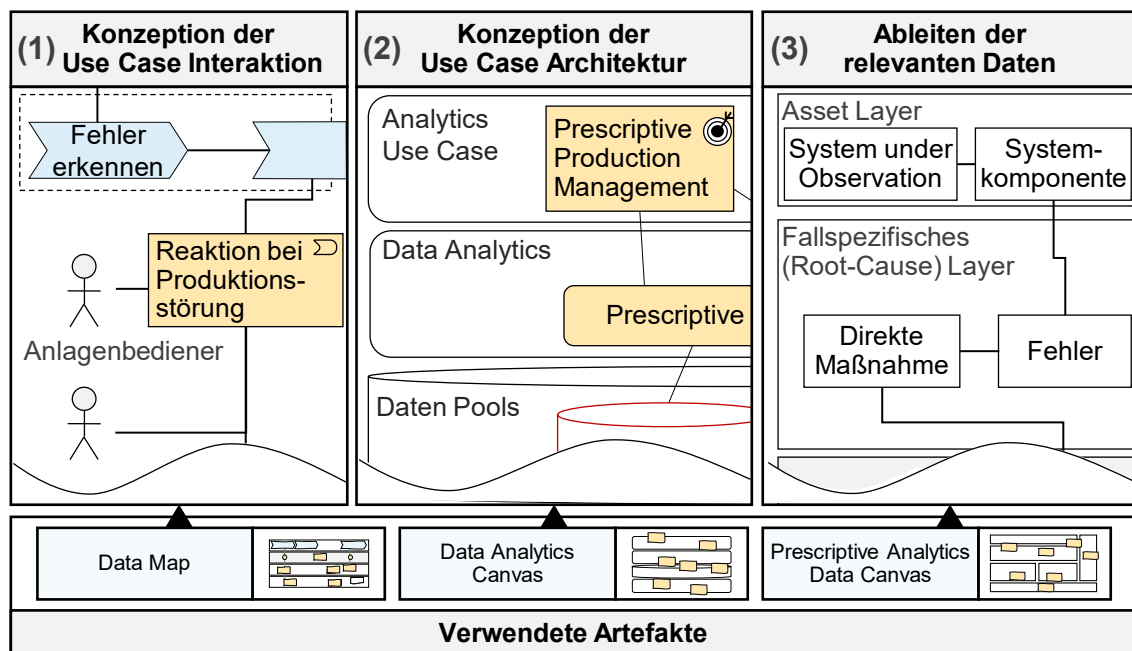


Bild 5-8: Phase zwei - Zusammenhänge bei der Ausdetaillierung der relevanten Inhalte zur Erzeugung der Use Case Konzepte

### Konzeption der Use Case Interaktion

Die **Konzeption der Use Case Interaktion** dient der Festlegung, wie der Use Case im späteren Arbeitsablauf zu integrieren ist. Dabei wird der spätere Nutzer mit einbezogen. Relevante Entscheidungen, Entscheider und Prozesse werden identifiziert. Basierend auf den Vorarbeiten der Prescriptive Analytics Use Case Transformation Canvas wurde die Kernfrage „Was muss getan werden, um den Normalzustand in der IoT Factory wiederherzustellen?“ identifiziert. Ein Überblick zum generellen Fokus des ausgewählten Use Cases ist Bild 5-9 zu entnehmen.

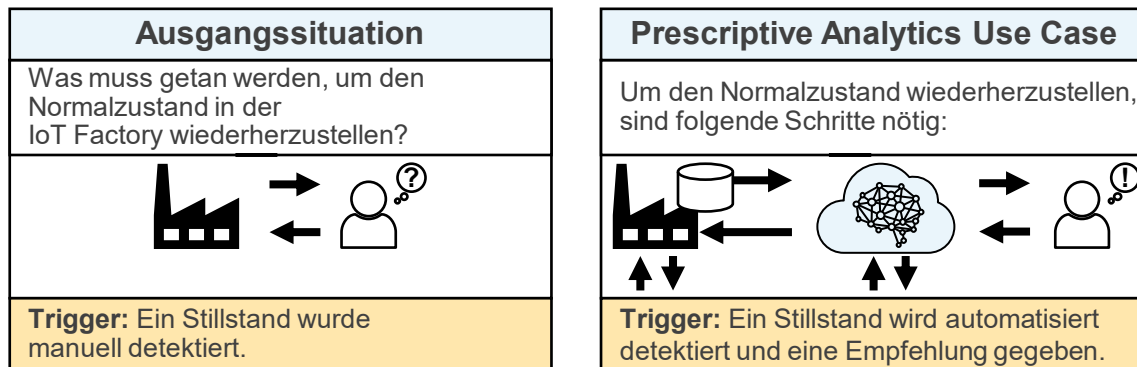


Bild 5-9: Einblick in die Vision des Prescriptive Production Management Use Cases

Die Kernfrage der **Ausgangssituation** ist eingebettet im übergeordneten Prozess des Produktions- und Instandhaltungsmanagements. Eine Unterstützung im **Prescriptive Analytics Use Case** bei der Entscheidung und Reaktion bei einer Produktionsstörung soll realisiert werden. Dazu gehören unter anderem die Schritte: Fehler erkennen, Entscheidungsalgorithmus nutzen, Feedback und Lernen. Durchgeführt wird der Entscheidungsprozess durch den Produktionsleiter. Eine weitere Ausdifferenzierung in Subentscheidungen gibt einen ersten Einblick in die Komplexität des Use Cases: Muss die Produktion umgeplant werden? Wird ein externer Techniker benötigt? Gibt es Auswirkungen auf andere Bereiche? Über die so vorgenommene Spezifikation des Use Cases werden die Betrachtungsgrenzen in der IoT Factory auf das unmittelbar betroffene Umfeld reduziert.

### Konzeption der Use Case Architektur und Ableiten der relevanten Daten

Die Partialmodelle der Use Case Architektur und Use Case Daten werden mithilfe der Analytics Canvas und Prescriptive Analytics Data Canvas gefüllt. Die Partialmodelle werden in Workshops unter Leitung des Analytics Architekten definiert, danach digitalisiert und in die Partialmodelle eingetragen (Vorgehen je Workshop siehe Kapitel 4.5.1) Zur Analyse der Randbedingungen werden die Partialmodelle zur Integration hinzugezogen.

**Use Case Architektur:** In den obersten zwei Ebenen (vgl. Bild 5-8, Details siehe Anhang A4.5) der Analytics Canvas werden die relevanten Use Cases und für die Use Cases benötigte Capabilities angegeben. Die weiteren Ebenen werden im Folgenden im Detail erläutert. Schnittstellen zwischen dem Prescriptive Production Management Use Case und anderen Use Cases bestehen in der Verarbeitungskette. Diagnose und Prädiktion können als Input genutzt werden, um einen möglichen Entscheidungsfall auszulösen. Der Use Case des Prescriptive Quality Management liefert weitere relevante Kontextdaten aus der IoT Factory. Der Use Case der Robot Cell Configuration stellt mögliche Trigger sowie einen direkten Eingriff in die IoT Factory bereit. In der IoT Factory fehlt eine Datenbank für Entscheidungsdaten. Einzig eine Datenbank für IoT Daten der IoT Factory ist verfügbar. Entscheidungsdaten, Präferenzen bei gleichwertigen Entscheidungen und generelles Problemlösungswissen liegen nicht digital vor.

**Use Case Daten:** Zur Erweiterung der ersten Erkenntnisse über die Datenbanken und Daten wird die Prescriptive Analytics Data Canvas ausgefüllt (vgl. Bild 5-10). Die darin vorgegebenen Datenfelder werden im Workshopformat schrittweise erarbeitet.

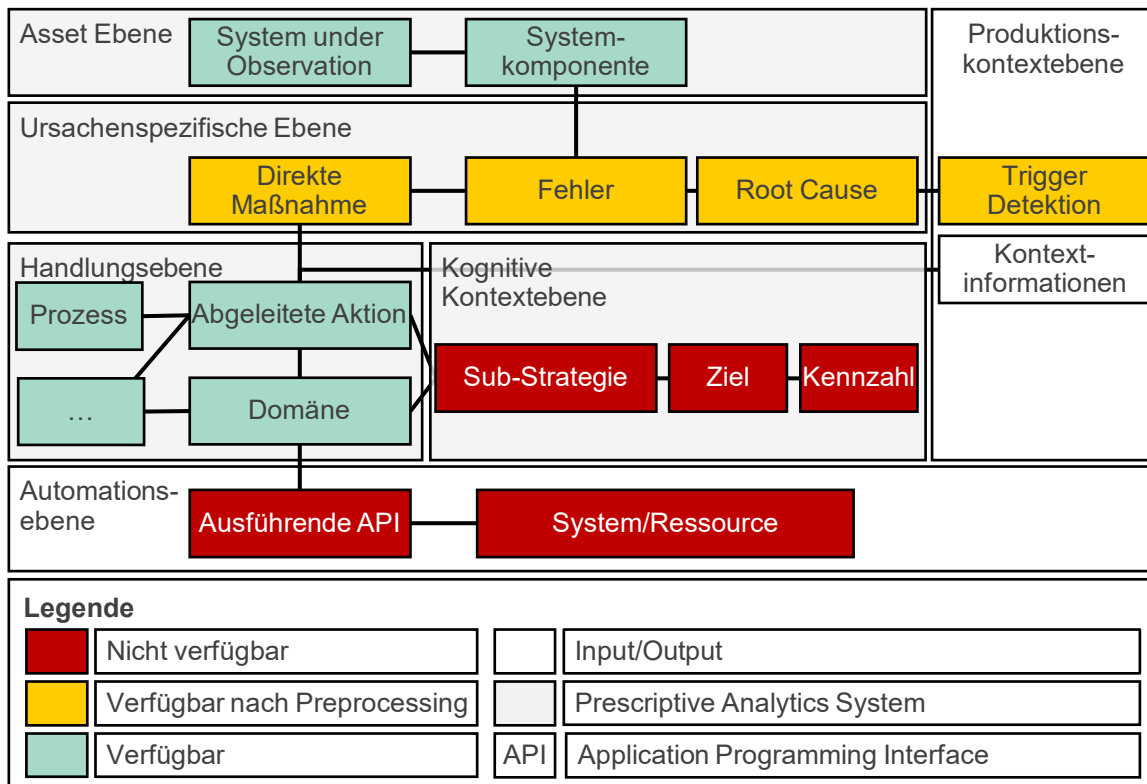


Bild 5-10: Ausgefüllte Prescriptive Analytics Data Canvas für den Prescriptive Production Management Use Case in der IoT Factory

Für die **Asset Ebene** sind alle Daten vorhanden, aber noch nicht strukturiert integriert. Die **ursachenspezifische Ebene**-Daten fehlen, sind aber prinzipiell durch Dokumente wie FMEAs<sup>19</sup> integrierbar. Aus der **Produktions-Kontextebene** werden die Auslöser der Handlungsempfehlung berücksichtigt. In der **Handlungsebene** sind die abgeleiteten Aktionen über Wartungsanleitungen verfügbar. Benötigte Informationen der **kognitiven Kontextebene** fehlen vollständig. Die **Automationsebene** ist im initial angestrebten Zielreifegrad nicht berücksichtigt. Für spätere Ausbaustufen wurde aufgenommen, welche Auswirkungen betrachtet werden müssen.

### 5.1.3 Prüfen der Integrierbarkeit

Übergeordnetes Ziel ist die Ermittlung von Synergiepotenzialen und möglichen Schnittstellen zwischen den einzelnen erarbeiteten Prescriptive Analytics Use Case Konzepten. Dazu wird im ersten Schritt die **Integrierbarkeit** der Use Case Konzepte in die gesamte

<sup>19</sup> FMEAs stellen ein in der Produktion verbreitetes Dokument dar. Fehlermöglichkeitseinflussanalysen (FMEAs) werden zur Ermittlung des Fehlerursprungs und dessen Auswirkung verwendet. Sie enthalten in der Regel auch Informationen zur Lösungsfindung (vgl. [KHK+20, TTX+04, BCJ+92]).

Architektur der IoT Factory **geprüft**. Basierend darauf werden Synergien und Querschnittsmaßnahmen Use Case übergreifend abgeleitet. Mithilfe der Analyse wird eine finale Roadmap für eine Implementierungsreihenfolge festgelegt. Ausführend sind der Analytics Architekt und Industrie 4.0 Manager. Der relevante Schritt aus dem übergeordneten Vorgehen ist in Bild 5-11 dargestellt.




Bild 5-11: Phase drei des übergeordneten Vorgehensmodells

Verwendet werden die Prescriptive Analytics Referenzarchitektur und die datenobjektbasierte Roadmap als Artefakte. Die Referenzarchitektur dient zur Sicherstellung einer skalierbaren Architektur. Die Roadmap wird primär zur Integration von Projektmanagementaspekten eingesetzt. **Kernergebnis** der dritten Phase ist eine **abgestimmte Use Case Roadmap**. Diese definiert die Festlegung auf die finale Menge an Prescriptive Analytics Use Cases zur Umsetzung.

Ein Überblick über den Schritt des Prüfens der Integrierbarkeit ist dem Bild 5-12 zu entnehmen. Im Übersichtsbild werden die relevanten Phasen, die verwendeten Artefakte (ausschnittsweise) sowie deren logische Zusammenhänge dargestellt.

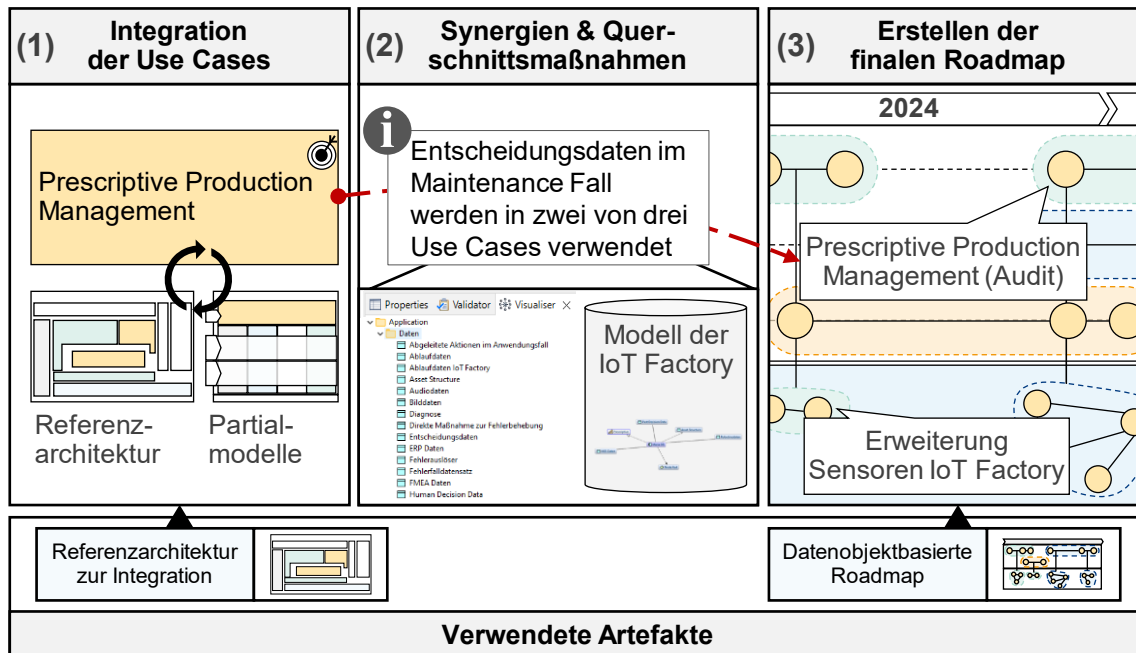


Bild 5-12: Phase drei - Zusammenhänge bei der Ausdetaillierung der relevanten Inhalte zur Erzeugung der abgestimmten Use Case Roadmap

### Integration der Use Cases

Die Integrierbarkeit der einzelnen Use Cases in die Unternehmensprozesse sowie die Applikations-, Daten- und technische Architektur wird einzeln basierend auf den Partialmodellen der Konzeption geprüft. Eine anschließende Fit-Gap Analyse mithilfe der in Phase eins initial angepassten Capability Map (siehe Kapitel 4.5.2) dient der Beurteilung der Aufwände zur Implementierung. Verwendet werden die Referenzarchitektur und alle Partialmodelle. Die Partialmodelle der Konzeption dienen als Input. Im Rahmen der technischen Architektur der IoT Factory (vgl. Bild 5-13) wird beurteilt, ob alle Elemente zum Abgreifen der benötigten Daten der einzelnen Use Cases vorhanden sind.

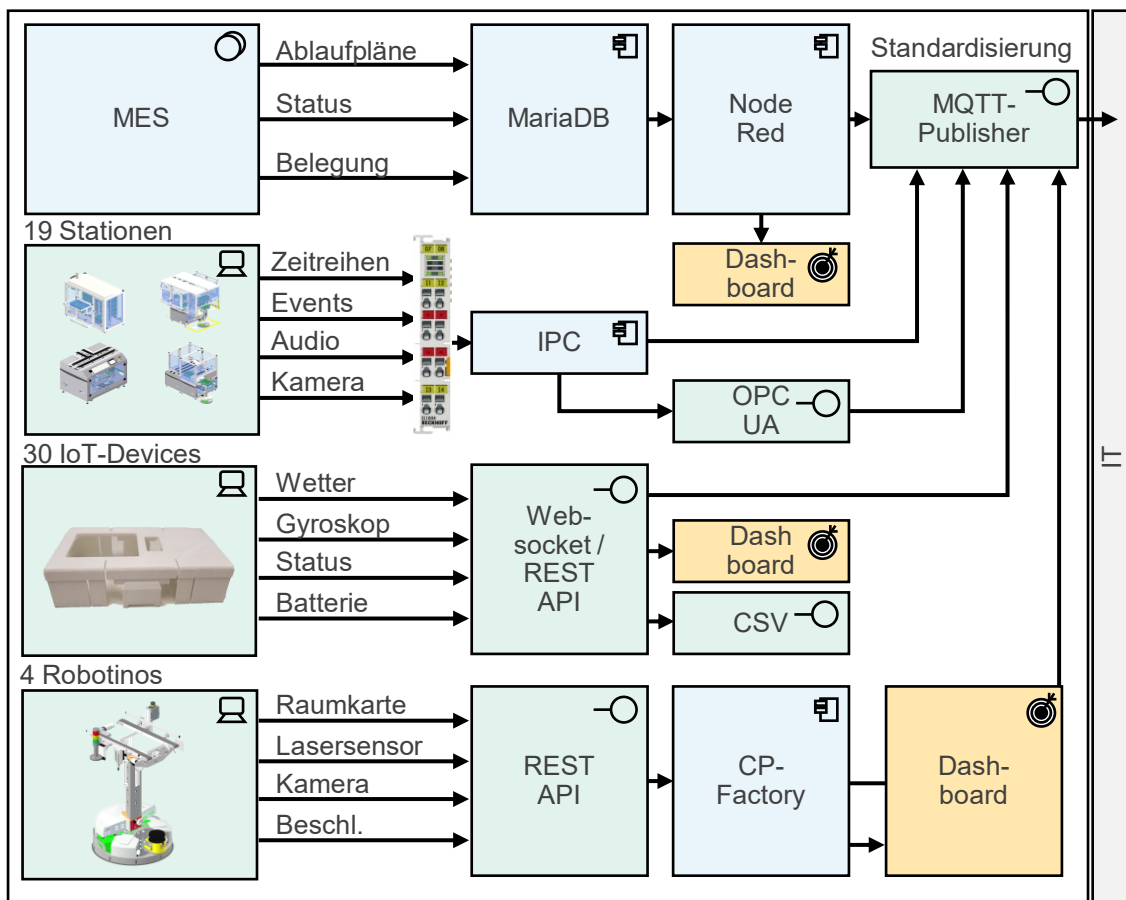


Bild 5-13: Einblick in die aufgebaute IT/OT-Infrastruktur der IoT Factory

Die **MES**-Daten sowie die **Robotino**-Daten sind verfügbar. Beim Beginn der Konzeption sind die erweiterten Sensorik-Informationen der **19 Stationen** nur von einer Roboterstation verfügbar. Die Daten der **IoT Devices** können zwar abgegriffen werden, wurden aber initial nicht abgespeichert. Generell steht eine Infrastruktur zur effizienten Datenübertragung aus der IoT Factory bereit. Dieselbe Analyse wird in allen die Integration betreffenden Partialmodellen durchgeführt. Dafür werden das Prozessmodell, die Applikationsarchitektur, der Datenkatalog sowie die technische Architektur der IoT Factory betrachtet. Eine detaillierte Darstellung der Applikationsarchitektur und des Datenkatalogs sind Anhang A4.7 zu entnehmen.

Eine Überprüfung der initial vorgenommenen Bewertung der Capabilities wird basierend auf den Partialmodellen der Use Case Konzepte durchgeführt. Die angepasste Bewertung wird im *Archi* Modell festgehalten. Der Schritt wird an dieser Stelle durchgeführt, da basierend auf den Konzepten erstmalig eine detaillierte Aussage möglich ist. Im Rahmen der IoT Factory haben sich keine signifikanten Änderungen bei der Bewertung des Ausgangszustandes der instanziierten Capability Map ergeben. Wäre dies der Fall, hätte dies einen direkten Einfluss auf die Bewertung des Aufwandes bei der Umsetzung der ausgewählten Use Cases. Die initiale Evaluation der Use Cases im Portfolio wird geprüft und eine finale relative Bewertung festgelegt. Capabilities, bei denen der Reifegrad nicht ausreichend ist, finden Berücksichtigung in der Roadmap.

### Synergien und Querschnittsmaßnahmen

Im Folgenden findet ein Perspektivwechsel auf alle Use Cases in der IoT Factory statt. **Synergien und Querschnittsmaßnahmen** werden mithilfe des *Archi* Modells teilautomatisiert erfasst. Aufbauend auf den Skripten zur Modellanalyse aus Kapitel 4.6.2 werden die konzipierten Use Cases verglichen. Das Ergebnis dient als Grundlage für das Ableiten der datenobjektbasierten Roadmap. Ein Beispiel aus der IoT Factory ist in Bild 5-14 dargestellt.

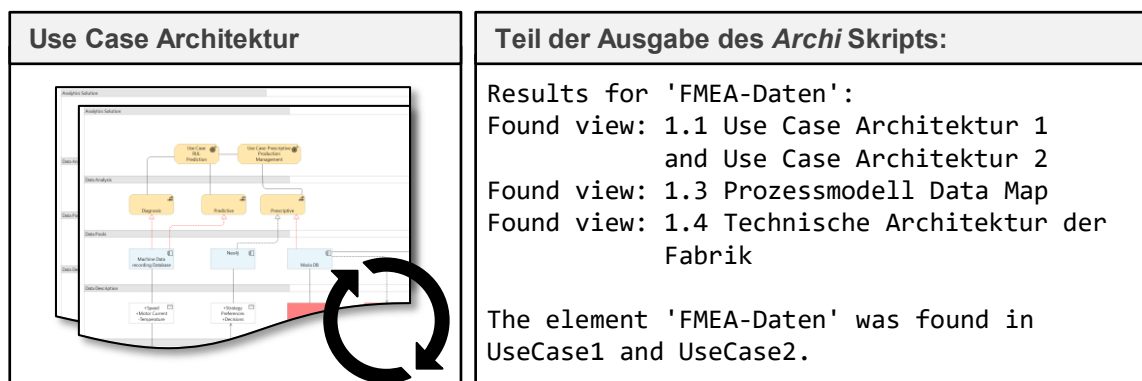


Bild 5-14: Werkzeuggestützte Analyse von Synergien zwischen den Prescriptive Analytics Use Cases in der IoT Factory

Basierend auf der Identifikation von mehrfach verwendeten neuen Datenschnittstellen werden die Aufwände von Use Cases durch die Ausgabe des *Archi* Skripts weiter präzisiert. Zurückgegriffen wird dafür auf die **Use Case Architektur**. Die **FMEA-Daten** werden für zwei der drei Use Cases benötigt. Daher ist die Bereitstellung dieser zu priorisieren. Neben der Verwendung von einer Datenschnittstelle wurden einige gemeinsame benötigte Datenobjekte identifiziert. Die Analyseergebnisse werden partialmodellübergreifend abgeleitet und ermöglichen so Erkenntnisse, die aus einer rein visuellen Betrachtung der Partialmodelle durch einen Nutzer nicht gewonnen werden können.

## Erstellen der finalen Roadmap

Eine abgestimmte Roadmap wird als final zur Umsetzung definiert. Sie basiert auf allen Erkenntnissen der vorherigen Phasen. Zur Erstellung wird das Artefakt der datenobjekt-basierten Roadmap verwendet. Inkludiert werden nur Use Cases, deren Aufwand-Nutzen-Verhältnis auch nach der Detaillierung im Rahmen der strategischen Ziele als vielversprechend beurteilt wird. Im Folgenden wird exemplarisch auf entdeckte Synergien und Abhängigkeiten zwischen den Use Cases eingegangen. Eine Übersicht über die Roadmap ist Bild 5-15 zu entnehmen.

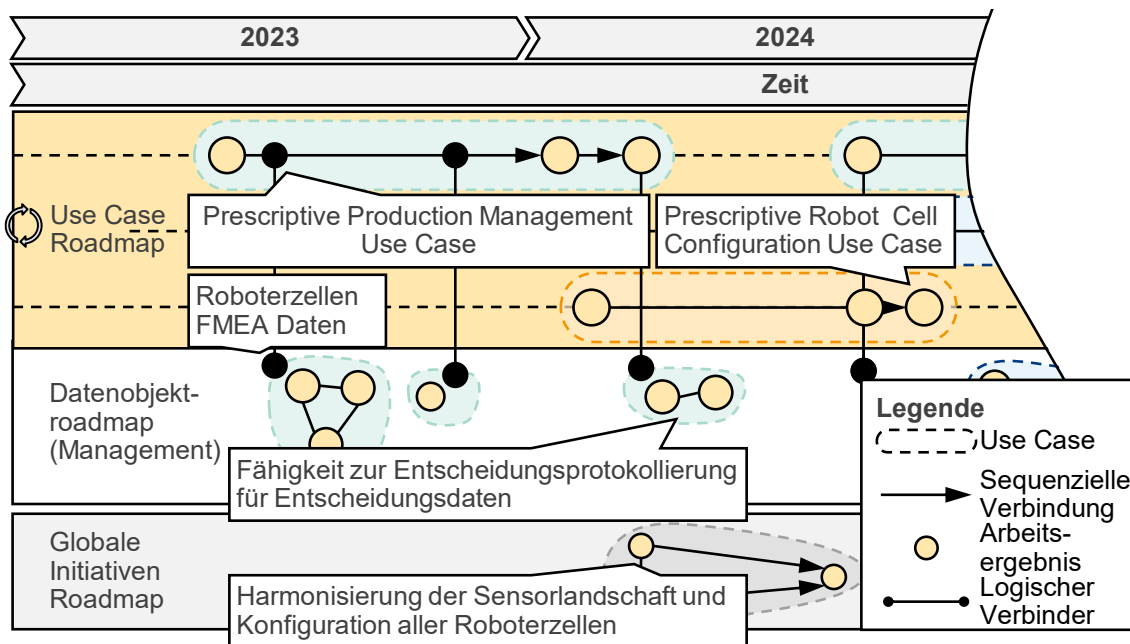


Bild 5-15: Roadmap für die Prescriptive Analytics Use Cases in der IoT Factory

Die Priorisierung aus dem initialen Portfolio wurde bestätigt. Wäre dies nicht eingetreten, würden die Use Cases in der Priorität im Portfolio angepasst und die entsprechenden Schritte des Vorgehens neu durchlaufen.

Für die Übertragbarkeit der Use Cases **Prescriptive Quality** und **Prescriptive Robot Cell Reconfiguration** von Roboterzelle zu Roboterzelle aus der **Use Case Roadmap** werden weitere Sensoren benötigt. Die dafür benötigten Daten sind in der **Datenobjekt-roadmap** gesammelt. Bisher sind die benötigten IoT Daten nur in einer Roboterzelle verfügbar. Diese werden aber auch für den Trigger für den Use Case **Prescriptive Production Management** benötigt. Es bietet sich an, die Abhängigkeit der Use Cases untereinander bei der Implementierungsreihenfolge zu nutzen.

Resultierende Maßnahmen sind in der **globalen initiativen Roadmap** gesammelt. Zuerst wird der Use Case Prescriptive Production Management umgesetzt. **FMEA-Daten** und ein Interface, um Entscheidungsdaten aufzunehmen, werden als erste Maßnahmen eingeplant. Sobald mehr Kontextdaten über die IoT Factory zur Verfügung stehen, werden die

Grundlagen für die Robot Cell Configuration durch die Implementierung eines Softsensors gelegt. Durch die Installation neuer Sensoren (Audio, Kraftmessung und Vibration) ist es nun möglich, die Roboterzellen gleich zu verwenden und die Transferierbarkeit von Produkten und Analytics Use Cases von Zelle zu Zelle zu testen.

Die Entwicklung des Prescriptive Quality Use Cases wird angestoßen, sobald Strategiedaten vorhanden sind. Dies bietet die Möglichkeit einer Präskription über ein triviales Mapping von Qualitätsabweichung und Handlung („Qualität wiederherstellen“) hinaus. Eine detaillierte Version der Roadmap ist dem Anhang A4.8 zu entnehmen.

#### 5.1.4 Detaillierung zur Umsetzung

Das folgende Kapitel beschreibt erneut ausschließlich den Prescriptive Production Management Use Case. Das übergeordnete Ziel der Phase ist die Bereitstellung von Konzepten mit einem Detaillierungsgrad, welcher für eine Umsetzung ausreichend ist. Generell sollte nach der **Detaillierung zur Umsetzung** eine Spezifikation aller technisch relevanten Teilaspekte zur Integration und Konzeption erfolgt sein. Darauf aufbauend wird eine erste Prescriptive Analytics Pipeline erarbeitet. Diese beantwortet im Gegensatz zur Architektur („Womit?“) die Frage „Wie?“ und fokussiert sich auf den Datenfluss und logischen Ablauf bei der Ausführung des Use Cases (Training und Inferenz).

Durchgeführt wird die Phase vom Analytics Architekt zur Aufbereitung der Ergebnisse für den Data Scientist. Der Data Scientist übernimmt die Ergebnisse zur Unterstützung für die Phasen Business Understanding, Data Understanding, Modeling und Deployment im CRISP-DM (vgl. Kapitel 2.5.6). Der relevante Schritt aus dem übergeordneten Vorgehen ist in Bild 5-16 dargestellt.




Bild 5-16: Phase vier des übergeordneten Vorgehensmodells

Als Artefakt wird die Prescriptive Analytics Referenzpipeline verwendet. **Detaillierte Konzepte je ausgewähltem Use Case zur Umsetzung** bilden das Kernergebnis der vierten Phase. Dies umfasst alle Partialmodelle und die Dokumentation der Entstehungsgeschichte der Partialmodelle (getroffene Designentscheidungen).

Ein Überblick über den Schritt der **Detaillierung zur Umsetzung** ist dem Bild 5-17 zu entnehmen. Im Übersichtsbild werden die relevanten Phasen, die verwendeten Artefakte sowie deren logische Zusammenhänge dargestellt.

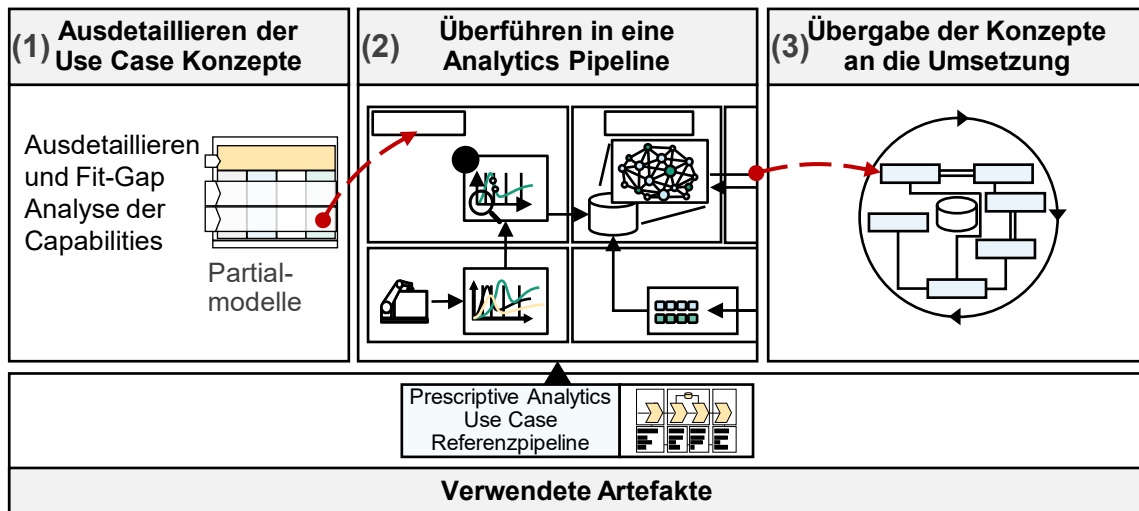


Bild 5-17: Phase vier - Zusammenhänge bei der Ausdetaillierung der relevanten Inhalte zur Erzeugung der finalen Konzepte zur Umsetzung

### Ausdetaillierung der Bestandteile

Bevor eine Prescriptive Analytics Pipeline konzeptioniert wird, müssen alle dafür relevanten **Partialmodelle ausdetailliert** werden. Dieser Schritt geschieht erst jetzt, damit der Aufwand nur für zur Umsetzung geplante Use Cases investiert wird. Alle Partialmodelle werden geprüft und der Detailgrad erhöht.

In der IoT Factory ergeben sich die größten Änderungen in der Informationsarchitektur. Beispielsweise wird das Datenobjekt „Entscheidungsdaten“ weiter ausdifferenziert in die verschiedenen für die Entscheidung benötigten Datenpunkte. Eine möglichst detaillierte Spezifikation einer initialen Prescriptive Analytics Pipeline wird erzeugt. So wird eine effiziente Weitergabe an die Umsetzung garantiert. Ein Überblick über die resultierende Pipeline ist Bild 5-18 zu entnehmen. Eine detailliertere Darstellung ist in Anhang A4.9 abgebildet. Die Pipeline und weitere Partialmodelle sollen auch in der Umsetzung des Konzepts Anwendung finden.

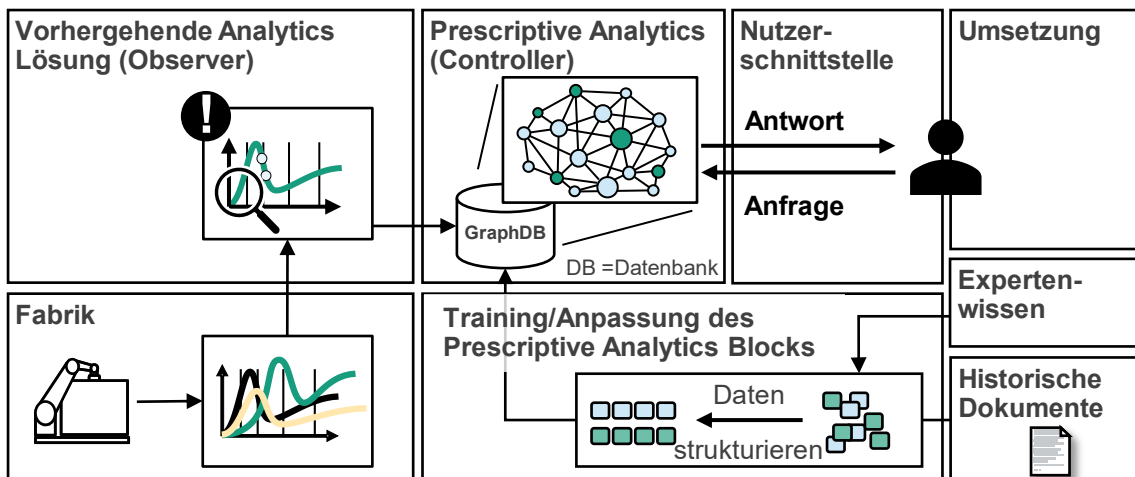


Bild 5-18: Prescriptive Analytics Pipeline für den Use Case aufbauend auf [NMW+25]

## Übergabe der Konzepte an die Umsetzung

Final werden die Konzepte zur Umsetzung an den Data Scientist übergeben. Es werden keine weiteren Artefakte zur Unterstützung aus der Spezifikationstechnik explizit neu genutzt. Im *VIP4PAPS* Projekt wurde begleitend eine Plattform für das Deployment der Lösungen entwickelt. Dies ist kein direkter Prescriptive Analytics Use Case, sorgt aber als Befähiger für eine einfache Skalierung bei zukünftigen Umsetzungsvorhaben. Die applikationsarchitekturbezogenen Aspekte für die IoT Factory wurden im Rahmen der *VIP4PAPS* Plattform umgesetzt (Details siehe Anhang A3).

## 5.2 Evaluation

Basierend auf der Demonstration der Spezifikationstechnik am Beispiel der IoT Factory wird diese abschließend evaluiert. Dies dient der letzten Phase der übergeordneten Forschungsmethode (siehe Kapitel 1.3). Die Spezifikationstechnik entspricht einem zusammenhängenden Gesamtartefakt (Englisch: Ensemble Artifact, vgl. [SHP+11]). Die Evaluationsumgebung entspricht einer naturalistischen [VPB12, S. 435]. Es ergibt sich daraus eine zulässige Menge an Methoden zur **Evaluation**, die im Folgenden genauer beschrieben werden.

Die Evaluation orientiert sich an drei übergeordneten Kriterien. Neben der Anwendbarkeit (gezeigt in der Demonstration) sind die Erreichung der Anforderungen aus der Problemanalyse sowie die Nutzbarkeitsaspekte (für die industrielle Anwendung) zu prüfen. Der Vergleich mit den übergeordneten Anforderungen wird für das Gesamtverfahren nach PEFFERS ET AL. benötigt [PTR+07, S. 56]. Die Nutzbarkeitsaspekte (essenziell nach PRAT ET AL. [PCA14, S. 7]) sind eine wichtige Dimension bei der Evaluation von Artefakten.

Die eingebetteten und integrierten Bestandteile aus dem Stand der Technik (z. B. Portfolioansätze) gelten als etabliert und eine entsprechende Evaluation der Anwendbarkeit als

einzelner losgelöster Betrachtungsgegenstand entfällt. Es werden nicht die einzelnen Artefakte evaluiert. Diese wurden in den entsprechenden Teilveröffentlichungen evaluiert (vgl. Tabelle 1-1). Die Evaluation der Teilveröffentlichungen (Artefakte) erfolgte somit iterativ, inkrementell und über den Erstellungszeitraum der Ausarbeitung. Dazu dienten Projekte aus der Erarbeitungszeit am FRAUNHOFER IEM.

In **Kapitel 5.2.1** wird die Bewertung der Erfüllung der erhobenen Anforderungen vorgestellt. Evaluationsinterviews mit relevanten Industrieakteuren werden in **Kapitel 5.2.2** erläutert. Neben der Erfassung des Feedbacks in Form einer Likert-Skala wird qualitatives Feedback als Grundlage für eine Diskussion erhoben.

### 5.2.1 Bewertung der Erfüllung der erhobenen Anforderungen

Im Einklang mit der Forschungsmethode (siehe Kapitel 1.3) werden die Anforderungen und Kernbestandteile der Spezifikationstechnik gegenübergestellt. Ein Überblick über den Beitrag der verschiedenen Aspekte der Spezifikationstechnik zur Anforderungserfüllung ist in Bild 5-19 visualisiert.

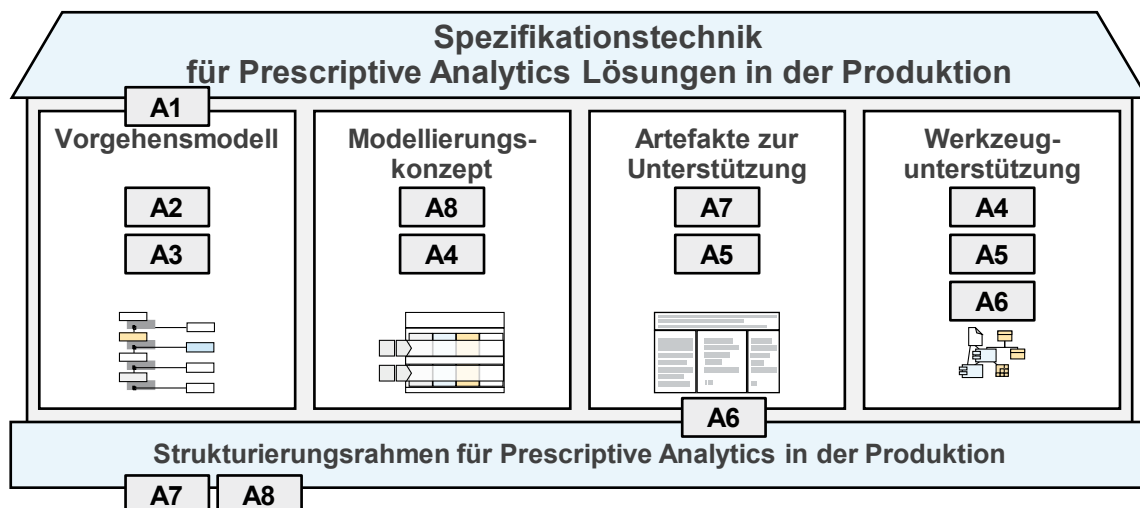


Bild 5-19: Gegenüberstellung der Spezifikationstechnik mit den Anforderungen (A)

Die **Bewertung der Erfüllung der erhobenen Anforderungen** aus der Problemanalyse dient dem Aufzeigen der generellen Zielerreichung des Entwicklungsvorhabens der Spezifikationstechnik nach PEFFERS ET AL. [PTR+07, S. 56]. Für einen detaillierten Überblick über die Anforderungen wird auf Kapitel 2.7 verwiesen. Im Folgenden wird auf jede Anforderung und ihre Einbindung in der Spezifikationstechnik kurz eingegangen.

#### Anforderung 1: Anwendbar für produzierende Unternehmen

Um das richtige Maß an Granularität in dem gegebenen Konzept zu finden, muss eine Lösung erreicht werden, die auf den Bereich der Produktion anwendbar ist. Diese Anforderung wird übergreifend durch die Spezifikationstechnik erfüllt. Die Gegebenheiten der Produktion werden insbesondere in der Wahl der Adressaten (siehe Kapitel 4.3.1), der

Wahl der Partialmodelle (siehe Kapitel 4.4), der Ausgestaltung der einzelnen Artefakte zur Unterstützung (Capability Map siehe Kapitel 4.5.2, Referenzpipeline siehe Kapitel 4.5.6, Referenzarchitektur siehe Kapitel 4.5.5) sowie der Auswahl gängiger Werkzeuge aus dem Bereich produzierender Unternehmen berücksichtigt (siehe Kapitel 4.6). Die bereits in produzierenden Unternehmen vorliegenden Data Analytics Use Cases werden durch die Prescriptive Analytics Use Case Transformation Canvas (siehe Kapitel 4.5.2) berücksichtigt und in das übergeordnete Vorgehen integriert.

### **Anforderung 2: Unterstützung beim Management der Synergien zwischen Use Cases**

Zur Sicherstellung eines vorteilhaften Aufwand-Nutzen-Verhältnisses bei der Auswahl von Prescriptive Analytics Use Cases müssen diese methodisch unterstützt und die Zusammenhänge zwischen ihnen gemanagt werden. Die Anforderung wird durch das Vorgehensmodell (siehe Kapitel 4.3) erfüllt. Der Fokus wird insbesondere auf die Zusammenhänge zwischen den einzelnen Use Cases gelegt. Weiterhin wird diese Anforderung durch die zur Verfügung gestellten Analysefragen (siehe Kapitel 4.6.2) für das *Archi* Modell unterstützt.

### **Anforderung 3: Unterstützung beim Vorgehen der Konzeption von Prescriptive Analytics Use Cases**

Ein strukturierter Ansatz zur Konzeption von Prescriptive Analytics Use Cases ist erforderlich, um die Integration und das Zusammenspiel der verschiedenen Use Cases im Unternehmenskontext zu gewährleisten. Diese Anforderung wird durch das Modellierungskonzept (siehe Kapitel 4.4.3) und das Vorgehensmodell (siehe Kapitel 4.3.1) unterstützt. Durch die Synchronisation zwischen Partialmodellen und Vorgehensmodell (siehe Kapitel 4.4.6) ist eine abgestimmte Nutzung sichergestellt.

### **Anforderung 4: Berücksichtigung unterschiedlicher Perspektiven für Prescriptive Analytics**

Für die Anwendung des Konzepts ist eine Verknüpfung von der strategischen mit der taktischen und operativen Ebene der Use Case Entwicklung erforderlich. Diese Verknüpfung wird durch das Modellierungskonzept (siehe Kapitel 4.4.5) bereitgestellt. Die drei Ebenen werden verknüpft und eine für die Anwendung sinnige Menge an Partialmodellen vorgeschlagen. Alle relevanten Perspektiven der Stakeholder werden berücksichtigt (siehe Kapitel 4.4.2). Wo möglich, wurden existierende etablierte Partialmodelle (z. B. Analytics Canvas und Data Map, siehe Kapitel 3) integriert.

### **Anforderung 5: Definition von Schnittstellen mit der bestehenden Unternehmensarchitektur**

Es ist essenziell, dass weitere Insellösungen bei neuen Use Case Entwicklungen in der Produktion verhindert werden. Neben der Berücksichtigung dieses Aspektes im Vorgehensmodell wird die Referenzarchitektur zur Integration und die Referenzpipeline für

Prescriptive Analytics Use Cases in der Produktion (siehe Kapitel 4.5.5 und Kapitel 4.5.6) zur Verfügung gestellt. Beide Referenzelemente stellen sicher, dass die Use Cases möglichst modular, integrierbar, wiederverwendbar und mit der Umgebung vernetzt entwickelt werden können.

### **Anforderung 6: Berücksichtigung der Integration zukünftiger Technologien**

Ein zentrales Element, welches Prescriptive Analytics Use Cases von anderen Analytics Use Cases unterscheidet, ist der starke Fokus auf eine zu treffende Entscheidung. Dieser wird ergänzt durch die Forderung nach einer lösungsneutralen Ausgestaltung der Spezifikation in der Anforderung. Beide Punkte werden durch die Prescriptive Analytics Capability Map (siehe Kapitel 4.5.2) adressiert. Diese ermöglicht die langfristige, vom Use Case und der Technologie unabhängige Planung der Transformation der Organisation. Mit Transformation ist hier die Transformation hin zu einer Prescriptive Analytics fähigen Organisation gemeint. Der Aspekt der Lösungsneutralität wird durch alle Elemente des Strukturierungsrahmens (siehe Kapitel 4.2) berücksichtigt.

### **Anforderung 7: Unterstützung bei der Umsetzung neuer Prescriptive Analytics Use Cases**

Die Umsetzungsmöglichkeiten bei der Konzeption spielen aufgrund ihrer Implikationen für die spätere Entwicklung eine große Rolle. Die Prescriptive Analytics Data Canvas (siehe Kapitel 4.5.4), Prescriptive Analytics Referenzpipeline (siehe Kapitel 4.5.6) und Prescriptive Analytics Referenzarchitektur (siehe Kapitel 4.5.5) unterstützen die Konzeption neuer Use Cases. Dies geschieht durch die Vorgabe eines Mindestmaßes an Modularisierung für Pipeline und Datenobjekte.

### **Anforderung 8: Analysierbare Zusammenhänge von Entscheidungen**

Prescriptive Analytics Use Cases können schwer einzeln betrachtet werden und sind oft eingebettet in einen komplexen Entscheidungszusammenhang. Zur Analyse der vernetzten Use Cases kann die Werkzeugunterstützung (siehe Kapitel 4.6) verwendet werden. Die Spezialisierung des Metamodells (siehe Kapitel 4.4.4) stellt einen generischen Ansatz bereit, der die Analyse der Gegebenheiten im System unter Observation und im Use Case erlaubt. So kann beispielsweise automatisiert geprüft werden, welche Akteure von mehreren Use Cases betroffen sind oder welche Datenobjekte besonders kritisch sind.

**Fazit:** Es lässt sich feststellen, dass durch den gewählten Ansatz alle Anforderungen an die *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* in vollem Umfang erfüllt sind. Die Eignung der Spezifikationstechnik für die erhobenen Anforderungen liegt somit vor. Insbesondere die Berücksichtigung unterschiedlicher Perspektiven bei der Konzeption von Prescriptive Analytics Use Cases ist ein integraler Bestandteil der Ausarbeitung und somit im besonderen Maße erfüllt.

## 5.2.2 Evaluationsinterviews zu Nutzbarkeitsaspekten

Im folgenden Kapitel wird ein Überblick über die Ergebnisse der **Evaluationsinterviews** gegeben. Zur Bewertung der Nutzbarkeitsaspekte müssen alle relevanten Rollen der Spezifikationstechnik (siehe Kapitel 4.3.3) in der Evaluierung berücksichtigt werden. Das heißt explizit, dass für die Planung (Industrie 4.0 Manager), Konzeption (Analytics Architekt), Integration (Analytics Architekt) sowie Umsetzung (Data Scientist und Analytics Architekt) alle Rollen berücksichtigt werden. Die Interviews werden basierend auf der Methode nach MYERS UND NEWMAN durchgeführt [MN07]. Zuerst wird die Bewertung von Evaluationskriterien auf einer Likert-Skala erfasst (siehe Anhang A4.10). Darüber hinaus wird qualitatives Feedback zu Nutzbarkeitsaspekten über Leitfragen herausgearbeitet. Dafür ist das Interview in die folgenden Teile gegliedert:

- Erfassen der **demografischen Daten** der Teilnehmenden
- **Vorstellung der Spezifikationstechnik** und Erläuterung bei Rückfragen
- **Quantitatives Feedback** und Erfassung auf Likert-Skala (Kernaspekt 1)
- **Qualitatives Feedback** gesteuert durch Leitfragen (Kernaspekt 2)

Die Interviews werden aufgezeichnet, maschinell transkribiert und Kernaussagen extrahiert. Diese werden im Nachgang thematisch gruppiert und zusammengeführt. Die Dauer jedes Interviews betrug eine Stunde. Die Leitfragen aus den Interviews sind dem Anhang zu entnehmen (siehe Anhang A4.10). Tabelle 5-1 gibt einen Überblick über die Interviewteilnehmenden und deren Rolle sowie relevante Analytics Erfahrung. Die strukturiert erfassten Ergebnisse der Evaluationsinterviews werden im Folgenden beschrieben.

*Tabelle 5-1: Überblick über die Interviewteilnehmenden (TN = Teilnehmer)*

Teilnehmer	Analytics Erfahrung	Rolle	Industrie
TN1	10 Jahre	Industrie 4.0 Manager	Automobilzulieferer
TN2	12 Jahre	Industrie 4.0 Manager	Sondermaschinenbau
TN3	6 Jahre	Analytics Architekt	Maschinen- und Anlagenbau
TN4	8 Jahre	Analytics Architekt	Verpackungsindustrie
TN5	9 Jahre	Data Scientist	Metallverarbeitende Industrie
TN6	7 Jahre	Data Scientist	Haushaltsgerätebau

### Kernaspekt 1: Strukturiertes Feedback mit Likert-Skala

Die verwendeten Dimensionen der Likert-Skala werden in Anlehnung an den Kriterien nach PRAT ET AL. aufgestellt [PCA14, S. 7]. Die Ergebnisse der strukturierten Abfrage in den Interviews sind in Tabelle 5-2 dargestellt.

Tabelle 5-2: Likert-Skala Ergebnisse (Skala eins (niedriger Erfüllungsgrad) bis vier (hoher Erfüllungsgrad), TN = Teilnehmer)

Teilnehmer	Kriterium							
	Übertrag in die Praxis		Beständigkeit der Ergebnisse		Vollständigkeit		Ausreichender Detailgrad	
TN1	4	<input type="text"/>	3	<input type="text"/>	4	<input type="text"/>	3	<input type="text"/>
TN2	2	<input type="text"/>	4	<input type="text"/>	3	<input type="text"/>	4	<input type="text"/>
TN3	2	<input type="text"/>	4	<input type="text"/>	3	<input type="text"/>	3	<input type="text"/>
TN4	2	<input type="text"/>	3	<input type="text"/>	4	<input type="text"/>	4	<input type="text"/>
TN5	2	<input type="text"/>	3	<input type="text"/>	4	<input type="text"/>	2	<input type="text"/>
TN6	2	<input type="text"/>	3	<input type="text"/>	3	<input type="text"/>	4	<input type="text"/>
<b>Mittelwert</b>	<b>2,3</b>	<input type="text"/>	<b>3,3</b>	<input type="text"/>	<b>3,5</b>	<input type="text"/>	<b>3,3</b>	<input type="text"/>

Ermittelt wurden die folgenden vier Dimensionen:

- **Übertrag in die Praxis:** Es wird abgefragt, inwieweit die Spezifikationstechnik mit ihren Bestandteilen im Unternehmenskontext des Interviewten direkt anwendbar ist.
- **Beständigkeit der Ergebnisse:** Im Vordergrund steht die Frage, wie die Langlebigkeit der Ergebnisse und Unabhängigkeit von kurzfristigen Trends und Elementen (z. B. schnell überholte Algorithmen oder Prinzipien) ist.
- **Vollständigkeit:** Diese Dimension berücksichtigt, inwieweit die Spezifikationstechnik den vorliegenden Problemraum für die interviewte Person in ihrem Unternehmen abdeckt (Effektivität).
- **Ausreichender Detailgrad der Unterstützung:** Es wird abgefragt, ob die Spezifikationstechnik in einem ausreichenden Maße bei der Bearbeitung der detaillierten Problemstellung unterstützt (Effizienz).

Der **Übertrag in die Praxis** wird fünf Mal mit zwei Punkten bewertet, da viele Voraussetzungen dafür in den Unternehmen noch nicht vollständig etabliert sind. Nur in einem interviewten Unternehmen sind die organisatorischen Voraussetzungen geschaffen. Auf diesen Aspekt wird im qualitativen Feedback genauer eingegangen. Die **Beständigkeit der Ergebnisse** wird als hoch bewertet. Die Evaluationsinterviews haben gezeigt, dass der Ansatz dem Anspruch der Ganzheitlichkeit bei einem **ausreichenden Detailgrad** gerecht wird. Von allen Teilnehmenden wird betont, dass der Ansatz in ihrem Unternehmen einen Mehrwert stiften kann. Die **Vollständigkeit** des Ansatzes wurde im Schnitt mit 3,5 Punkten bewertet. Dies betont noch einmal aus Industrieperspektive die Ausrichtung auf die in den Unternehmen vorliegenden Herausforderungen.

### Kernaspekt 2: Qualitatives Feedback

Das qualitative Feedback wurde aufgenommen und in Form von Kernaussagen gesammelt. Diese Kernaussagen wurden thematisch gruppiert und für die Darstellung in der

Ausarbeitung aggregiert (Wortlaut angeglichen). Ein Überblick über die Ergebnisse der thematischen Gruppierung ist der Tabelle 5-3 zu entnehmen. Die wörtlichen Zitate können dem Anhang A4.10 entnommen werden.

*Tabelle 5-3: Übersicht über die Vorteile und bleibenden Herausforderungen bei der Anwendung der Spezifikationstechnik*

<b>Vorteile</b>	<b>Bleibende Herausforderungen</b>
<ul style="list-style-type: none"> <li>• Die Ganzheitlichkeit des Konzepts schafft einen guten Überblick für alle Akteure, welche Perspektiven in der Use Case Entwicklung benötigt werden. (TN1, TN2, TN3, TN5)</li> <li>• Die Strukturiertheit der einzelnen Teilaspekte hilft, mehr Transparenz im Use Case Entwicklungsprozess zu schaffen. (TN2, TN3, TN4)</li> <li>• Man kann gut auf existierenden Dokumentationen im Unternehmen den Analytics Teil aufsetzen. In bisherigen Data Analytics Projekten fehlt dieses Dokumentationsrahmenwerk. (TN6, TN4)</li> <li>• Insbesondere nach Projektende kann man mithilfe der Spezifikationstechnik getroffene Designentscheidungen nachvollziehen. Dies liegt vor allem an der sinnvoll gewählten Werkzeugunterstützung. (TN1, TN3)</li> <li>• Die Spezifikationstechnik trägt zur Externalisierung von Expertenwissen und damit indirekt zum internen Wissensmanagement in der Organisation bei. (TN4, TN6)</li> </ul>	<ul style="list-style-type: none"> <li>• Das Konzept erfordert ganzheitlichen Top Down Ansatz im Unternehmen der nicht immer gegeben ist. (TN2, TN5, TN6)</li> <li>• Die Rolle des Analytics Architekten fehlt teilweise im Unternehmen. Es wird aber anerkannt, dass die Rolle eines Analytics Architekten benötigt wird. Im Ist-Stand wird sich hier oft aufgrund fehlender interner Expertise oder Ressourcen mit externen Beratern oder Moderatoren ausgeholfen. (TN4, TN6)</li> <li>• Die Aspekte der Synchronisation der verschiedenen Rollen bei der Entwicklung und in Richtung CRISP-DM können noch weiter detailliert und definiert werden. (TN1, TN5)</li> <li>• Die geforderten Partialmodelle liegen gerade in vielen verschiedenen Werkzeugen bei verschiedenen Abteilungen vor. (TN1, TN2, TN3, TN4)</li> <li>• Ein Permutationskonzept wird benötigt, um nur Teile des Konzepts nutzen zu können (für den Mittelstand oder um initial den Nutzen für das Management aufzeigen zu können). (TN2)</li> <li>• Die Aufwände zur Modellierung der einzelnen Partialmodelle sind, wenn Vorarbeiten fehlen, hoch. (TN1, TN3)</li> </ul>

Es wird von den Teilnehmern positiv hervorgehoben, dass auf existierenden Ansätzen im Unternehmen aufgebaut wird. Der Charakter der kontinuierlichen Dokumentation und Qualitätssicherung ist ein Vorteil der Spezifikationstechnik. Ergebnis der Einführung der Spezifikationstechnik ist aber auch immer ein Change-Projekt und eine Änderung der Arbeitsweise der betroffenen Rollen (TN2, TN3). Herausfordernd bleibt der Grad an Komplexität in der Modellierung und Use Case Entwicklung. Zu weiteren Herausforderungen zählen die Rolle des Analytics Architekten sowie die Medienbrüche zwischen den verschiedenen dokumentierten Partialmodellen in verteilten Werkzeugen. Weiterhin sind die Aufwände zur Modellierung ohne passende Vorarbeiten bei einer Neueinführung von

den Teilnehmern als hoch bewertet worden (TN1, TN3). Neben dem oftmals nicht etablierten Systemdenken (TN4) sind auch fehlende interne Analytics Capabilities eine Herausforderung (TN2, TN3, TN4). Als Erweiterung des Konzepts wird von TN5 die Integration eines Chatbots zur geführten Anwendung der Spezifikationstechnik vorgeschlagen.

**Fazit:** Die Evaluationsinterviews haben die Gebrauchstauglichkeit bestätigt. Sie ersetzen keine langfristige Studie zur Nutzung und Effizienzsteigerung im Unternehmen durch den Einsatz der Spezifikationstechnik. Es wird lediglich ein erster Indikator für die Weiterführung des erarbeiteten Ansatzes gegeben. Die qualitative Abschätzung der Gebrauchstauglichkeit durch die spezifizierte Nutzergruppe wird als hinreichendes Maß zur Bestätigung der Evaluationskriterien angenommen.

### 5.3 Diskussion der Ergebnisse

Die qualitativen Ergebnisse der Evaluationsinterviews dienen als Grundlage für die **Diskussion der Ergebnisse**. Die vorgestellte *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* trägt verschiedene Aspekte zur Forschung und Praxisarbeit bei. Die Ergebnisse der bisherigen Evaluation werden im Folgenden in Bezug auf den Stand der Technik, das Forschungsfeld des Advanced Systems Engineerings, die Integrierbarkeit und die Übertragbarkeit kritisch diskutiert.

Dafür wird in **Kapitel 5.3.1** der Beitrag der Spezifikationstechnik zum Stand der Technik herausgearbeitet. **Kapitel 5.3.2** ordnet die Ausarbeitung im Kontext der Schule des Advanced Systems Engineerings ein. Die Integrierbarkeit und Übertragbarkeit der Lösung werden in **Kapitel 5.3.3** diskutiert.

#### 5.3.1 Beitrag der Spezifikationstechnik

Durch die Spezifikationstechnik wird ein Beitrag dazu geleistet, die Spezifikation von Prescriptive Analytics Use Cases und damit die Operationalisierung zu beschleunigen (Herausforderungen vgl. [HHS24, GBW22, McC24]). Der **Hauptwertbeitrag der Spezifikationstechnik** ist die Vernetzung veröffentlichter Teilaspekte. Die Vernetzung wird durch ein Vorgehensmodell und Modellierungskonzept bereitgestellt. Die Werkzeugunterstützung ist primär zur Befähigung des Einsatzes der Spezifikationstechnik gedacht. Sie stellt ohne die anderen Hauptelemente keine sinnvoll losgelöste Einheit dar. Allgemein dient sie der Erhöhung der Praxistauglichkeit der Einzelbestandteile. Im Folgenden wird der Beitrag je vom Gesamtkonzept angeschnittenem Forschungsfeld kurz beleuchtet. Dafür wird auf die Industrial Data Science, Produktion sowie das EAM separat eingegangen. Final wird ein übergeordneter Blickwinkel eingenommen.

**Industrial Data Science und Entwurfstechnik Analytics** (siehe Kapitel 2.3): Kern der Ausarbeitung ist die Vernetzung und Integration von Use Case Konzepten. Die Spezifi-

kationstechnik stellt Artefakte bereit, welche bei der Entwicklung von integrierten Lösungen unterstützen. Es wird die Grundlage gelegt, Lösungswissen in der bereitgestellten Spezialisierung im Einklang mit den vorgeschlagenen Partialmodellen effizient und wiederverwertbar für Prescriptive Analytics Use Cases zu nutzen. Entsprechend wurden Ansätze wie die Analytics Canvas und Data Map als etablierte Vorarbeiten integriert [KJR+18, JEK+19]. Ein vorher nicht vorhandenes Vernetzungskonzept wird bereitgestellt und Einzellösungen werden harmonisiert. Dies bietet eine Grundlage für weitere Entwicklungstätigkeiten und die Harmonisierung zwischen verschiedenen Forschungsartefakten. Einflüsse von Teillösungen auf ausgewählte Herausforderungen aus der Problematik (vgl. Kapitel 1.1) werden in Tabelle 5-4 zusammengefasst.

Tabelle 5-4: Durch die Ausarbeitung beantwortete Herausforderungen

Aufruf zur Forschung	Beantwortung durch die Ausarbeitung
WINDMANN ET AL.: Kombination von IT und OT für Analytics Use Cases verbessern und dabei KI-Systeminfrastruktur und deren Planung verbessern. [WWS+24]	Die übergeordnete Herausforderung der Kombination von IT und OT wird durch das Modellierungskonzept sowie die Referenzarchitektur adressiert (siehe Kapitel 4.4).
MARTINEZ ET AL.: Fehlende Koordination von Gesamtzusammenhängen bei der Entwicklung von Analytics Use Cases und fehlende Governance Aspekte für Analytics. [MVO21]	Der Aspekt wird durch das Vorgehensmodell adressiert. Es stellt einen Ansatz bereit, mehrere einzelne Use Case Entwicklungen ganzheitlich aus einer Architekturmanagementperspektive heraus zu betrachten (siehe Kapitel 4.3.1).
GABRIEL ET AL.: Fehlendes Komplexitätsmanagement und unzureichende Transparenz bei der Entwicklung von KI- und Data Science Lösungen in der Produktion. [GFG+24, S. 22]	Für das Komplexitätsmanagement wird die Verwendung von EAM-Werkzeugen wie <i>Archi</i> für Prescriptive Analytics Use Case Entwicklungen demonstriert (siehe Kapitel 4.6). Dies kann als Blaupause zur weiteren Verwendung von EAM-Ansätzen für das Komplexitätsmanagement bei der Systemintegration von IDS Use Cases dienen.
WISSUCHEK ET AL.: Steigende Menge an Prescriptive Analytics Systemen [WZ24, S. 33] bei gleichzeitig fehlender organisatorischer Verankerung von Prescriptive Analytics Systemen. [WZ24, S. 39]	Die Planung der Prescriptive Analytics Infrastruktur und die organisatorische Verankerung werden durch die Prescriptive Analytics Capability Map aus einer Organisationsperspektive unterstützt (siehe Kapitel 4.5.2).

Die Ausarbeitung leistet einen Beitrag zur stärkeren Formalisierung und Vernetzung von Einzellösungen und der Spezifikation dieser in der Industrial Data Science (insbesondere für Prescriptive Analytics). Der Begriff der „Konzeption von Prescriptive Analytics Lösungen“ wurde im Rahmen der Ausarbeitung aus der Perspektive der Industrial Data Science geprägt.

**Produktion und Enterprise Architecture Management** (siehe Kapitel 2.5): Der Beitrag der Ausarbeitung ist im Besonderen eine Unterstützung bei der Integration in existierende IT-Systeme der Produktion (vgl. [HHS24, S. 32, BHF+23, S. 6]). Im Zentrum steht die Detaillierung zur Umsetzung von höheren Reifegradstufen der Industrie 4.0 Reifegradbewertung nach ACATECH [SAD+20]. Der Neuheitsgrad im Rahmen der Ausarbeitung ist die Anwendung etablierter Ansätze des EAMs (z. B. Aufbau auf dem Metamodell von *ArchiMate* [Lan17, S. 136]) im Bereich der Industrial Data Science. Etablierte Ansätze aus dem EAM wie die modellbasierte Unternehmensarchitekturanalyse (vgl. [Stu18]) werden aufgegriffen und für Prescriptive Analytics Use Cases erstmalig angewendet.

Ansätze aus dem EAM werden bereits vielfältig für andere Domänen instanziiert. Zum Beispiel finden sie Anwendung zur Planung von Nachhaltigkeitsinitiativen in Unternehmen (vgl. [VvP23]) oder bei der Einführung des digitalen Fabrikzwillings (vgl. [LDK+24]). Die Nutzung des EAMs soll die Etablierung und einfachere Verbreitung der Spezifikationstechnik in Unternehmen vereinfachen. Dies gilt insbesondere für diese, die bereits etabliert EAM betreiben. So wird ein Brückenschlag zwischen EAM und Analytics Systemkonzeption und -umsetzung geschaffen. Die Spezifikationstechnik leistet einen Beitrag, konkrete Mehrwerte des EAMs aufzuzeigen.

**Übergeordnete Perspektive:** Neben den Perspektiven der einzelnen Forschungsfelder gilt es, übergeordnet die Ergebnisse der Ausarbeitung einzuordnen. Die Konzeption von Prescriptive Analytics Use Cases wird unterstützt, vereinfacht und in ihrer Komplexität verringert (vgl. Forderung von ACATECH [Aca24, S. 57]). Dieses Feld wurde bisher nur von Ansätzen mit nicht verbundenen Perspektiven bearbeitet (z. B. Data Map oder Analytics Canvas, siehe Kapitel 3.2). Ein Vorteil des gewählten Abstraktionsgrades der Spezifikationstechnik liegt in der inhärenten Technologieoffenheit (somit langfristige Anwendbarkeit) und Ganzheitlichkeit des strukturierenden Gesamtkonzepts. Übergreifende Aspekte werden berücksichtigt, etablierte Ansätze aufgegriffen und an Ansätze anderer Abstraktionsgrade angelehnt. Der Hauptwertbeitrag gegenüber dem Stand der Technik ist somit die sinnvolle Instanzierung und Verbindung von Aspekten aus der Dimension der Entwurfstechnik Analytics (für Industrial Data Science) und Aspekten des EAMs für das Spezialgebiet der Prescriptive Analytics Use Cases in der Produktion.

Allgemein liegt eine starke Abhängigkeit von den Capabilities der ausführenden Rollen bei der Lösungskonzeption vor. Die Ausarbeitung leistet einen Teilbeitrag, um die Lücke zwischen benötigtem (vgl. [HHS24]) und erreichtem Analytics Potenzial (vgl. [GBW22]) in der Produktion zu schließen. Die größte Einschränkung in Bezug auf die übergreifende Anwendung in der Praxis liegt in dem Umstand, dass viele der integrierten Partialmodelle in anderen Werkzeugen gemanagt und erzeugt werden oder komplett offline vorliegen (andere Anwendersysteme) [Lan17, S. 44, MHD22, S. 123, KR22, S. 46]. Mögliche Unzulänglichkeiten der vorgeschlagenen Bestandteile der Spezifikationstechnik werden nachfolgend kurz zusammengefasst:

- **Organisationsperspektive:** Der Betrachtungszeitraum zur Evaluation ist kurz (Dreijahresprojekt) gewählt. Dieser ist nicht ausreichend, um eine langfristige Wirtschaftlichkeitsbetrachtung zu ermöglichen. Die Aufwand-Nutzen Bewertung der Prescriptive Analytics Use Cases bleibt eine Herausforderung im Kontext der Produktion.
- **Betrachtungsobjekt zur Demonstration:** Weiterhin sind in einer Forschungsfabrik (IoT Factory Gütersloh) manche Gegebenheiten als idealisiert anzunehmen. Hierzu zählen die Verfügbarkeit von Personal und die realen Betriebsstunden der Anlagen.
- **Artefakt der Spezifikationstechnik:** Das Konstrukt der Spezifikationstechnik ersetzt Kreativität und Gewissenhaftigkeit bei der Ausgestaltung der Prescriptive Use Case Entwicklung nicht. Sie dient als Hilfestellung mit der Gratwanderung zwischen Übersystematisierung und fehlender Unterstützung.
- **Voraussetzungen in der Forschung:** Algorithmen und Ansätze für Prescriptive Analytics sind teilweise noch nicht vollumfänglich ausgereift (vgl. GARTNER Hype Cycle für Prescriptive Analytics [Gar22b]). Hier basiert die Ausarbeitung auf der Annahme, dass, wie von Gartner prognostiziert, Prescriptive Analytics in den nächsten drei bis fünf Jahren sein Plateau erreicht.
- **Ganzheitlichkeit des Ansatzes:** Der Ansatz adressiert ebenenübergreifend die Rolle des Analytics Architekten (siehe Kapitel 4.3). Es besteht die Gefahr, dass durch die holistische Perspektive die adressierten Rollen im Unternehmen verstreut vorliegen und somit die direkte praktische Einsetzbarkeit erschwert wird (vgl. Evaluationsinterviews, Kapitel 5.2.2).

### 5.3.2 Einordnung in das Advanced Systems Engineering

Die Paderborner Schule der Entwurfstechnik hat die Gestaltung intelligenter technischer Systeme (Produkte) sowie das Unternehmen mitsamt den Engineering Prozessen und der Produktion im Fokus. Zur **Einordnung in das Advanced Systems Engineering** werden die Anknüpfungspunkte betrachtet. Die Ausarbeitung als Teil des Wirkgefüges stellt eine Schnittstelle zwischen der strategischen Planung und Unternehmensführung sowie der Modellierung von intelligenten technischen Systemen aus dem Systems Engineering dar. Aus dem Teilgebiet der strategischen Planung werden Ansätze von LIPSMEIER und GABRIEL im Besonderen für die managementgerechte Gestaltung des Vorgehensmodells herangezogen (vgl. [Lip21, GKD23]). Aus dem Teilgebiet der Modellierung von komplexen Systemen durch modellbasiertes Systems Engineering (vgl. [TDB+15]) oder EAM (vgl. [Lan17]) wird auf Ansätze aus CONSENS (vgl. [Fra06]) sowie Ansätzen zur Gestaltung von Engineering IT-Architekturen zurückgegriffen (vgl. [Hei24]).

Die Ausarbeitung überträgt existierende Ansätze aus dem Systems Engineering (für Produkte) auf das Engineering von Unternehmen. Dabei stellt die Rolle des Analytics Architekten ein vergleichbares Profil zum Systems Engineer dar. Hierbei wird diese Rolle vorgedacht. Bewährte Modellierungsansätze aus dem MBSE werden aufgegriffen und der

Übertrag in die Gedankenwelt der Entwurfstechnik von Analytics Lösungen auf die spezielle Domäne der Produktion wird geleistet. Im Vergleich zum klassischen Systems Engineering von Produkten ist der Grad der Grobplanung auf einer High Level Architektur nur in bedingtem Maße geeignet, um die spätere Performance von Use Cases abzuschätzen. Dies liegt insbesondere an der Abhängigkeit von Use Cases von Ausnahmefällen und kleineren Umsetzungsdetails [HSP+21, S. 5]. Dementsprechend bleibt die Einbindung von Experten bei einem bleibenden Restrisiko unabdingbar.

Die Spezialisierung schafft eine Grundlage für die Systematisierung und Dokumentation von Lösungsmustern. Dabei strukturiert ein Lösungsmuster relevantes Lösungswissen und dient der Wiederverwendung von etablierten Mustern [Ana15, S. 7]. Ein Übertrag dieses Konzepts für Analytics Use Cases wurde von VON ENZBERG ET AL. vorgeschlagen [ENM+20, S. 11]. Eine Wiederverwendung von Lösungsmustern kann durch einen Modellspeicher (ein sogenanntes „Repository“) verschiedenen Endnutzern zur Verfügung gestellt werden. Dies bietet die Chance, generische Analytics Use Case bezogene Inhalte in eine definierte Struktur aufzunehmen und wiederverwendbar zur Verfügung zu stellen. Dieser Ansatz wird im Rahmen der Ausarbeitung nicht weiterverfolgt. Trotzdem werden dafür durch die Spezifikationstechnik die Grundlagen gelegt.

### 5.3.3 Integrierbarkeit und Übertragbarkeit

Zur Analyse der **Integrierbarkeit und Übertragbarkeit** werden die Erkenntnisse aus der Demonstration und Evaluation im Hinblick auf die Anwendung in produzierenden Unternehmen kritisch reflektiert. Die durchgehende Demonstration der Ausarbeitung erfolgte in einem nicht wirtschaftlich agierenden Teilbereich einer Forschungsfabrik. Dies begründet sich im vorliegenden Projektkontext und den für die umfangliche Demonstration benötigten Zeitrahmen. Eine Anwendung von Teilaspekten der Spezifikationstechnik erfolgte in Auftragsforschungsprojekten in Kooperation mit einem Maschinen- und Anlagenbauer (Umsetzung von drei Use Cases in einem System under Observation) und einem produzierenden Unternehmen.

Bleibende Herausforderungen sind insbesondere das verteilte Vorliegen von Eingangsinformationen, der Modellierungsaufwand, die fehlende Unterstützung bei der Wahl des Detaillierungsgrades und die in Unternehmen teilweise noch nicht stark ausgeprägte Rolle des Analytics Architekten.

Zur Beurteilung der Integrierbarkeit der Spezifikationstechnik sind das **Vorgehensmodell** sowie das **Modellierungskonzept** zu untersuchen. Das **Vorgehensmodell** lehnt sich an etablierte Management- und Planungsvorgehen an (vgl. [Lip21]) und instanziiert diese für den Bereich (Prescriptive) Analytics Use Cases in der Produktion. Die Einordnung des Vorgehens in übergeordneten Ebenen ist in Anlehnung an [Lip21, Moc21, S. 163, GKD23] und aufbauend auf den Vorveröffentlichungen erfolgt [WMK+24, EWB+24]. Bei Bedarf kann das Vorgehen an unternehmensspezifische Managementaspekte angepasst werden. Das **Modellierungskonzept** wird in der praktischen Anwendung dadurch

beschränkt, dass viele der Partialmodelle in verschiedenen Werkzeugen vorliegen. Daher werden für Werkzeuganbieter und Gesamtlösungsanbieter Schnittstellen identifiziert. Für die Spezifikation von Prescriptive Analytics Use Cases relevante Schnittstellen werden in Bild 5-20 zusammengefasst.

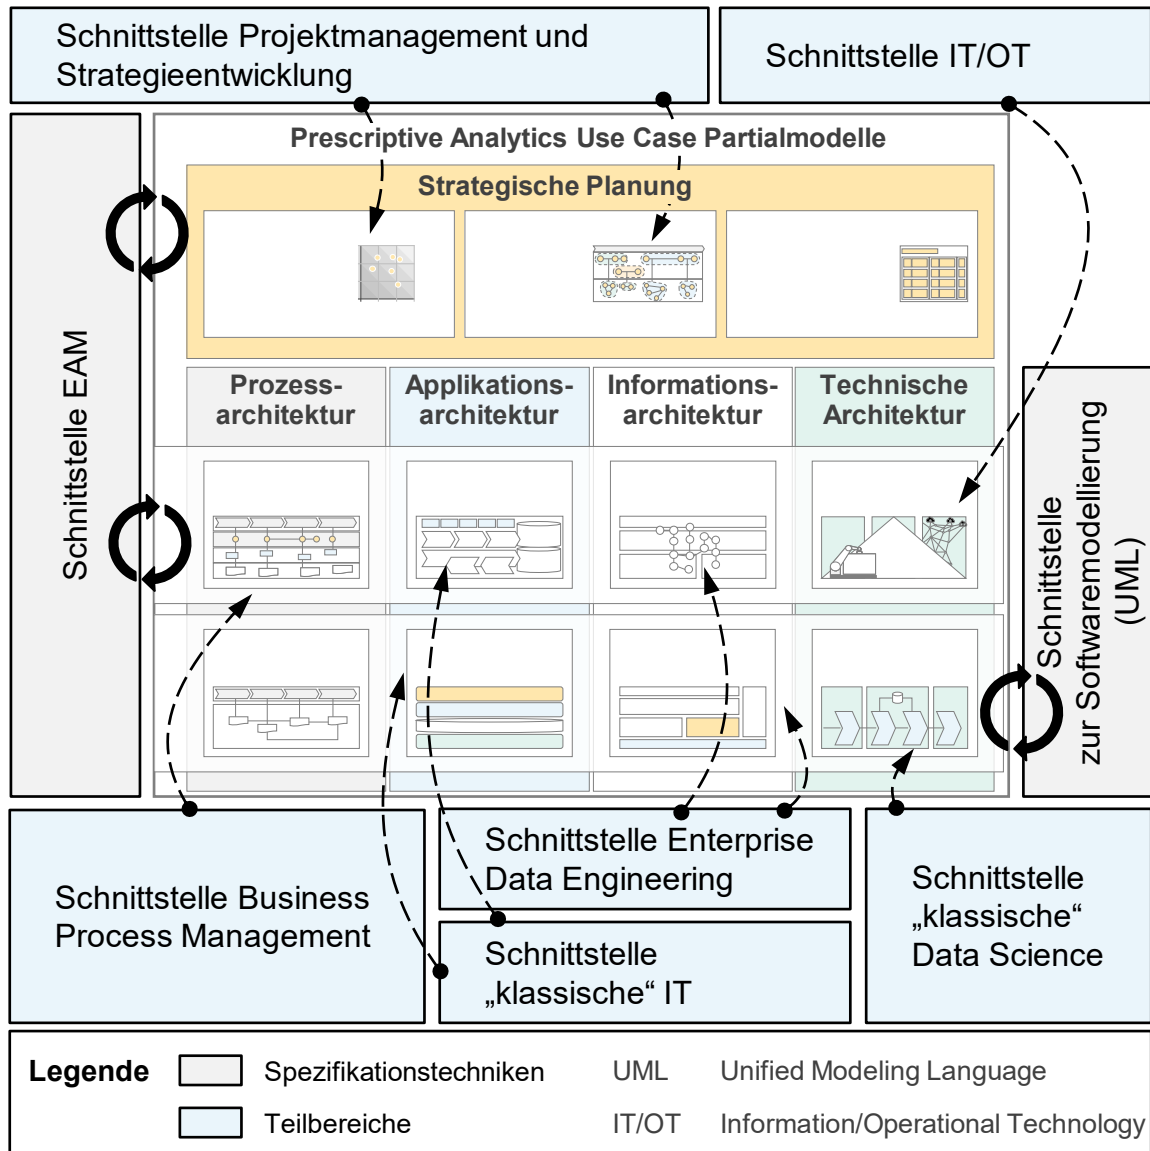


Bild 5-20: Schnittstellen zu anderen Domänen und relevanten Bereichen

Schnittstellen in Form von ähnlichen Modellierungszielen oder Modellierungsansätzen existieren zu dem **Projektmanagement**, der **Strategieentwicklung**, der **Automatisierungstechnik**, dem **Enterprise Data Engineering**, dem **Business Process Management**, der klassischen **IT/OT** und **Data Science**. Die Werkzeugunterstützung in *Archi* birgt mögliche Anknüpfungspunkte. Für das *ArchiMate* Metamodell gibt es definierte Schnittstellen zu Spezifikationen der **Softwaretechnik** (z. B. UML) [Lan17, S. 136]. Eine Verknüpfung zu Ansätzen der SysML (Modellierung von Produkten als System) ist denkbar, aber nicht im Standard vorgesehen. Zur Anwendung der Ergebnisse in anderen

Kontexten (z. B. Fabrikplanung) wird ein Ansatz zur Instanziierung und Konfiguration benötigt. Dieser ist durch weitere Forschungsarbeit herzuleiten. Die Artefakte zur Unterstützung bleiben auch mit steigendem Expertenwissen der Anwender relevant, da sie primär strukturgebende Elemente und Vorgehensweisen bereitstellen. Die Langlebigkeit der Lösung wird durch den gewählten Abstraktionsgrad sichergestellt.

**Gesamtfazit und Verwendung der Inhalte im erweiterten Gültigkeitsbereich:** Basierend auf der Diskussion lässt sich ein Instanziierungskonzept für die Ausarbeitung ableiten. Das Gesamtkonzept könnte auch für andere komplexe Analytics Use Cases genutzt werden. Da die Inhalte in diesem Kontext nicht evaluiert sind und viele der Artefakte zur Unterstützung auf den speziellen Fall von Prescriptive Analytics Use Cases zugeschnitten sind, lässt sich dafür aber keine allgemeingültige Empfehlung aussprechen. Weitere Forschung (und insbesondere Evaluation) ist in diesem Bereich nötig, um eine abschließende Aussage treffen zu können. Dies beinhaltet die Anpassung an andere Projektmanagementansätze, Metamodelle, Werkzeuge oder Analytics Vorhaben.



## 6 Zusammenfassung und Ausblick

Abschließend wird die Erarbeitung der Spezifikationstechnik zusammengefasst und die Kernbeiträge werden hervorgehoben. Basierend auf den Kernergebnissen und den Grenzen der Untersuchung wird der anschließende Forschungsbedarf abgeleitet.

Produzierende Unternehmen befinden sich in einem Spannungsfeld bestehend aus Faktoren wie dem Fachkräftemangel, dem zunehmenden globalen Wettbewerb und der Transformation hin zu einer nachhaltigen Produktion. Ein Ansatz zur Begegnung dieser Veränderungstreiber ist die Vision der Industrie 4.0. Prescriptive Analytics dient der Umsetzung der Reifegradstufen Vorausschau und Adaption für die Vision der Industrie 4.0. Dies kann in der Produktion insbesondere durch den Einsatz von Prescriptive Analytics Lösungen zur Entscheidungsunterstützung erreicht werden. Dennoch sind Prescriptive Analytics Lösungen bisher wenig verbreitet. Einer der Hauptgründe dafür ist die **mangelnde Unterstützung der ganzheitlichen Entwicklung** der Prescriptive Analytics Lösungen. Um eine ganzheitliche Entwicklung zu ermöglichen, wurde eine *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* entwickelt. Den Rahmen der Ausarbeitung bildet die Forschungsmethode der Design Science Research Methodology nach *PEFFERS ET AL.* [PTR+07]. Die DSRM dient als Struktur für eine iterative Entwicklung.

Zu Beginn wird in **Kapitel 2** die **Problemanalyse** beschrieben. Die Umsetzung von Prescriptive Analytics Use Cases ist durch die Erweiterung des Datenraums in der Produktion um Aktionen und Handlungen herausfordernd. Weiterhin werden Prescriptive Analytics Use Cases mit anderen Use Cases in der Produktion vernetzt, um Synergiepotenzial zu erzeugen. Dies hat zur Folge, dass ein größerer Planungshorizont mit umfassenderen Auswirkungen auf die existierende Produktion betrachtet werden muss. Die Entwicklung von Prescriptive Analytics Use Cases wirkt sich auch auf die zu betrachtenden Architekturebenen aus. Aus dieser Problematik ergeben sich drei zu adressierende Handlungsfelder. Neben dem ganzheitlichen Vorgehen für die Entwicklung von Prescriptive Analytics Use Cases und der Konzeption von Prescriptive Analytics Use Cases muss Gestaltungswissen für Prescriptive Analytics Use Cases betrachtet werden. Aus den drei Handlungsfeldern folgen acht spezifische Anforderungen mit Fokus auf die Planung, Konzeption und Integration von Prescriptive Analytics Use Cases für die Produktion. Die Adressierung der Anforderungen erfordert einen holistischen und interdisziplinären Ansatz, der Aspekte aus dem Management der Produktion sowie der Entwicklung von Prescriptive Analytics Use Cases berücksichtigt. Konkret werden ein Vorgehensmodell, ein Modellierungskonzept, Artefakte zur Unterstützung sowie eine Werkzeugunterstützung benötigt.

Ziel von **Kapitel 3** ist es, den **Stand der Technik** unter Berücksichtigung der Anforderungen aus der Problematik zu analysieren. Übergeordnet werden Ansätze aus den Berei-

chen der ganzheitlichen Entwicklung von Analytics Lösungen und Artefakte zur Analytics Konzeption untersucht. Weiterhin werden existierende Referenzarchitekturen zur Use Case Integration sowie Ansätze zur Strukturierung von Prescriptive Analytics Systemen untersucht. Keine triviale Kombination der existierenden Ansätze erfüllt die Anforderungen der Problematik. Somit ist eine Entwicklung einer neuen Lösung basierend auf der Integration sinnvoller Aspekte des Stands der Technik unabdingbar.

**Kapitel 4** stellt die entwickelte *Spezifikationstechnik für Prescriptive Analytics Lösungen in der Produktion* vor. Als **Strukturierungsrahmen** der Spezifikationstechnik dient Grundlagenwissen zu Prescriptive Analytics Use Cases. Dafür werden eine Taxonomie für Use Cases, Design Prinzipien zur Use Case Entwicklung und eine Übersicht zur Strukturierung von Use Case Identifikationsmechanismen zur Verfügung gestellt. Hauptwertbeitrag der Ausarbeitung stellt das Vernetzungskonzept etablierter Bestandteile zur ganzheitlichen Entwicklung von Prescriptive Analytics Use Cases für die Produktion dar. Die Spezifikationstechnik besteht weiterhin aus vier Kernbestandteilen:

- 1) Das **Vorgehensmodell** strukturiert die nötigen Schritte von einer losen Menge an Use Case Ideen hin zu ausgereiften Konzepten für eine definierte Anzahl an Prescriptive Analytics Use Case Lösungen. Dafür werden die strategische, taktische und operative Ebene adressiert. Je Schritt im Vorgehensmodell sind Sub-Vorgehensschritte, Adressaten und Kernergebnisse definiert.
- 2) Das **Modellierungskonzept** zur Integration von Prescriptive Analytics Lösungen in die Produktion unterstützt die Konzeption. Ein Fokus wird auf die Integration von Prescriptive Analytics Lösungen in eine existierende Produktionsumgebung gelegt. Die Unterstützung ist durch ein Partialmodell- und Vernetzungskonzept realisiert.
- 3) Als ergänzende **Artefakte zur Unterstützung** dienen eine Canvas zur Use Case Transformation sowie eine Capability Map für Prescriptive Analytics Use Cases in der Produktion. Zur Unterstützung bei der Modellierung werden eine Referenzarchitektur zur Integration und eine Referenzpipeline für die Analytics Aspekte bereitgestellt.
- 4) Mithilfe einer **Werkzeugunterstützung** wird die Operationalisierung in den Anwenderunternehmen für die Zielgruppe der Analytics Architekten sichergestellt. Zurückgegriffen wird auf ein Sprachprofil des Metamodells *ArchiMate* und das Modellierungswerkzeug *Archi*.

**Kapitel 5** fokussiert sich auf die **Demonstration** der Anwendbarkeit der Spezifikationstechnik. Die IoT Factory Gütersloh dient als Anwendungsbeispiel. Diese ist aufgrund eines klar umrissenen Umfangs sowie einer beherrschbaren Komplexität bei einer größtmöglichen Praxistauglichkeit (Format eines Testbeds) besonders geeignet für die Demonstration. Zum Zeitpunkt der Anwendung der Spezifikationstechnik sind bereits erste nicht Prescriptive Analytics Use Cases in der IoT Factory umgesetzt. Die Spezifikationstechnik wird auf den Betrachtungsgegenstand angewendet. Das Vorgehen wird vollständig durchlaufen und alle vorgestellten Artefakte verwendet. Durch eine erfolgreiche Demonstration werden die Anwendbarkeit und Praxistauglichkeit aufgezeigt.

Darauf aufbauend wird die **Evaluation der Spezifikationstechnik** beschrieben. Die Evaluation findet zweigeteilt statt. Zuerst wird die Erfüllung aller Anforderungen aus der Problemanalyse festgestellt und eine Zuordnung zu den Beiträgen der Ausarbeitung hergestellt. Mithilfe einer Nutzerevaluation (sechs Interviews) mit Industriepartnern wird die Begehrlichkeit der erzeugten Inhalte gezeigt. Abschließend werden alle Ergebnisse inklusive Limitationen in Bezug auf die Einordnung in den aktuellen Stand der Technik diskutiert. Dazu gehören der aktuell hohe Aufwand zur Modellierung und der Umstand, dass in der Praxis die Partialmodelle oft über Systeme verteilt vorliegen.

Im Kontext der übergeordneten Erkenntnisse zur Konzeption von Prescriptive Analytics Lösungen für die Produktion besteht Bedarf für anschließende Forschungstätigkeiten. Die **Erweiterung der Spezifikationstechnik** auf einen breiteren Anwendungskontext (nicht nur Prescriptive Analytics Lösungen) steht im Vordergrund. Weiterhin ist die Schnittstelle zu den einzelnen Umsetzungsschritten (CRISP-DM) bisher nur angerissen und bietet daher Potenzial für weitere Unterstützungsansätze bei der Entwicklung von Analytics Use Cases. Eine Erweiterung könnte auch durch das Ableiten eines Permutationskonzepts ermöglicht werden. Die im Rahmen der Ausarbeitung genutzte Werkzeugunterstützung ist nur prototypisch. Diese kann zu einem schlüsselfertigen Softwaretool erweitert werden. Das Nutzen von Chatbots zur semi-automatisierten Führung durch die Spezifikationstechnik ist zu prüfen. Die Erarbeitung weiterer Artefakte zur Verankerung der Spezifikationstechnik fußt unmittelbar auf der Rolle des Analytics Architekten. Dessen Rolle sowie die Einführung einer Analytics Architekturplanung in eine Organisation kann noch in größerem Maße unterstützt werden. Dies könnte zum Beispiel in Form eines reifegrad-spezifischen Einführungskonzepts konkretisiert werden. Aspekte wie die Wahl des Detaillierungsgrades und Update-Mechanismen der Modelle sind noch offene Fragestellungen. Folgende Punkte sollten aus der **Perspektive der Forschungsfelder** adressiert werden:

- **Perspektive Produktion:** Der Prozess von der Analytics Strategie bis zum einzelnen Use Case wurde im Rahmen der Ausarbeitung angerissen. Insbesondere der Aspekt der Analytics Strategie ist in der Praxis noch heterogen ausgeprägt und bietet Potenziale zum Ableiten von standardisierten Archetypen.
- **Perspektive Industrial Data Science:** Die teilautomatische Generierung von präskriptivem Wissen und Informationen aus Expertendokumenten, z. B. durch generative KI ist ein Schlüsselkonzept für den vorgestellten Ansatz. Hier gilt es insbesondere neben Expertenwissen einen Fokus auf die präskriptiven Wissensanteile in zukünftigen Forschungsvorhaben zu legen.
- **Perspektive Entwurfstechnik Analytics:** Die Spezifikationstechnik bietet die Option, Lösungsmuster für die Use Cases standardisiert zu erfassen und die Wiederverwendbarkeit zu erhöhen. Dafür kann neben der Systematisierung die Verwendung von Foundation-Modellen untersucht werden. Neben dem Fine-Tuning von Foundation-Modellen zur Generierung von Partialmodellen ist die semi-automatische Erstellung der Modelle basierend auf offline Workshopdokumentationen von Interesse.



**Abkürzungsverzeichnis**

ADACIS	International Conference on Advances in Data-driven Analytics and Intelligent Systems
API	Application Programming Interface
B2A	Business to Analytics
BMW	Bayerische Motoren Werke AG
BPMN	Business Process Modeling Notation
CIRP	College International pour la Recherche en Productique
CMS	Conference on Manufacturing Systems
CONSENS	CONceptual design Specification technique for the ENgineering of complex Systems
CPPS	Cyber-physisches-Produktionssystem
CPS	Cyber-physisches-System
CPSL	Conference on Production Systems and Logistics
CRISP-DM	Cross Industry Standard Process for Data Mining
CRM	Customer Relationship Management
D3M	Data-Driven Decision Making
DMME	Data mining methodology for engineering applications
DP	Design Prinzip
DSRM	Design Science Research Methodology
EAM	Enterprise Architecture Management
ECIS	European Conference on Information Systems
ERP	Enterprise Resource Planning (System)
FMEA	Fehlermöglichkeits- und Einflussanalyse
FRUCT	Free Researchers Union on Communication Technologies
HDFS	Hadoop distributed file system
HMI	Human-Machine-Interface
ICME	Intelligent Computation in Manufacturing Engineering
IDS	Industrial Data Science
IEEE	Institute of Electrical and Electronics Engineers
IEM	Institut für Entwurfstechnik Mechatronik
IoT	Internet of Things
IT	Information Technology (Informationstechnologie)
KDD	Knowledge Discovery in Databases
KI	Künstliche Intelligenz
KPI	Key-Performance-Indikator
MDPI	Multidisciplinary Digital Publishing Institute
MES	Manufacturing Execution System
ML4CPS	Machine Learning for Cyber Physical Systems
MQTT	Message Queuing Telemetry Transport

---

NOSQL	Not only SQL
OEE	Overall Equipment Efficiency
OMEGA	Objektorientierte Methode zur Geschäftsprozessmodellierung und -analyse
OPC-UA	Open Platform Communication Unified Architecture
OT	Operational Technology
PAS	Prescriptive Analytics System
Prod. Mmt.	Production Management
REST	Representational state transfer
RUL	Remaining Useful Lifetime
SQL	Structured Query Language
TN	Teilnehmer
TOGAF	The Open Group Architecture Framework
UML	Unified Modeling Language
vgl.	Vergleiche
VIP4PAPS	VIP+ (Förderformat) for (4) Prescriptive Analytics Platform(s)
z. B.	zum Beispiel

## Literaturverzeichnis

- [AAB+20] ADI, E.; ANWAR, A.; BAIG, Z.; ZEADALLY, S.: Machine learning and data analytics for the IoT. *Neural Computing and Applications*, (32)20, 2020, S. 16205–16233
- [AAE23] AMERICAS HEADQUARTERS; ASIA PACIFIC HEADQUARTERS; EUROPE HEADQUARTERS: Cisco AI Readiness Index – Intentions Outpacing Abilities, 2023
- [AB95] ALMEIDA, A. T. DE; BOHORIS, G. A.: Decision theory in maintenance decision making. *Journal of Quality in Maintenance Engineering*, (1)1, 1995, S. 39–45
- [ABO+17] ADESANWO, M.; BELLO, O.; OLORODE, O.; EREMIOKHALE, O.; SANUSI, S.; BLANKSON, E.: Advanced analytics for data-driven decision making in electrical submersible pump operations management. *SPE Nigeria Annual International Conference and Exhibition 2017*; Lagos; Nigeria; 31 July 2017 through 2 August 2017; Code 133002, 2017
- [Aca24] ACATECH - FORSCHUNGSBEIRAT INDUSTRIE 4.0– DEUTSCHE AKADEMIE DER TECHNIKWISSENSCHAFTEN: Engineering autonom wandelbarer Industrie 4.0-Systeme – Expertise des Forschungsbeirats Industrie 4.0, 2024
- [ADF+17] ANDERSON, N.; DIAB, W. W.; FRENCH, T.; HARPER, K. E.; LIN, S.-W.; NAIR, D.; SOBEL, W.: *Analytics Framework*. Editiert von Diab, Wael William; Harper, K. Eric; Lin, Shi-Wan; Mellor, Stephen; Waddell, Russell, 2017
- [AGN19] ANSARI, F.; GLAWAR, R.; NEMETH, T.: PriMa: a prescriptive maintenance model for cyber-physical production systems. *International Journal of Computer Integrated Manufacturing*, (32)4-5, 2019, S. 482–503
- [AGS20] ANSARI, F.; GLAWAR, R.; SIHN, W.: Prescriptive Maintenance of CPPS by Integrating Multimodal Data with Dynamic Bayesian Networks. In: Beyrer, J.; Maier, A.; Niggemann, O. (Hrsg.): *Machine Learning for Cyber Physical Systems. Technologien für die intelligente Automation*, Springer Berlin Heidelberg, Berlin, Heidelberg, 2020, S. 1–8
- [Alk23] ALKHALDI, F.: Maximizing Business Potential: A Framework for Implementing Prescriptive Analytics. In: Yaseen, S. G. (Ed.): *Cutting-Edge Business Technologies in the Big Data Era – Proceedings of the 18th SICB “Sustainability and Cutting-Edge Business Technologies” Volume 2. Studies in Big Data*, 136, Springer Nature Switzerland; Imprint Springer, Cham, 2023, pp. 251–259

- [Ana15] ANACKER, H.: Instrumentarium für einen lösungsmusterbasierten Entwurf fortgeschrittener mechatronischer Systeme – Dissertation. HNI Verlagsschriftenreihe, 2015
- [ASM+12] AHLEMANN, F.; STETTNER, E.; MESSERSCHMIDT, M.; LEGNER, C.: Strategic Enterprise Architecture Management. Springer Heidelberg Dordrecht London New York- Management for Professionals, 2012
- [Aue18] AUER, J.: Industry 4.0 – digitalisation to mitigate demographic pressure – Germany Monitor - The digital Economy and structural change. Deutsche Bank Research, 2018
- [Bau17] BAUERNHANSL, T.: Die vierte industrielle Revolution – Der Weg in ein wertschaffendes Produktionsparadigma. In: Vogel-Heuser, B.; Bauernhansl, T.; Hompel, M. ten (Hrsg.): Handbuch Industrie 4.0 Bd.4 – Allgemeine Grundlagen. 2. Auflage, VDI Springer Reference, Springer Berlin Heidelberg, Berlin, Heidelberg, 2017
- [BCJ+92] BELL, D.; COX, L.; JACKSON, S.; SCHAEFER, P.: Using causal reasoning for automated failure modes and effects analysis (FMEA): Annual Reliability and Maintainability Symposium, S. 343–353
- [BEF+22] BEYERER, J.; EISENTRÄGER, M.; FREY, C.; HERZOG, C.; MOGHISEH, A.; MORAND, L.; PFROMMER, J.; STEPHANI, H.; STOLL, A.; WESSELS, L.: ML4P-Vorgehensmodell: Machine learning for production, 2022
- [BEK+23] BROCK, J.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Process Mining Data Canvas: A method to identify data and process knowledge for data collection and preparation in process mining projects. Procedia CIRP, (119), 2023, S. 602–607
- [BGB22] BASHIR, M. R.; GILL, A. Q.; BEYDOUN, G.: A Reference Architecture for IoT-Enabled Smart Buildings. SN computer science, (3)6, 2022
- [BGM+21] BUCHGEHER, G.; GABAUER, D.; MARTINEZ-GIL, J.; EHRLINGER, L.: Knowledge Graphs in Manufacturing and Production: A Systematic Literature Review. IEEE Access, (9), 2021, S. 55537–55554
- [BHF+23] BUDDE, L.; HÄNGGI, R.; FRIEDLI, T.; RÜEDY, A.: Smart Factory Navigator – Identifying and Implementing the Most Beneficial Use Cases for Your Company—44 Use Cases That Will Drive Your Operational Performance and Digital Service Business. Springer, 2023
- [BIT11] BITKOM: Enterprise Architecture Management – neue Disziplin für die ganzheitliche Unternehmensentwicklung. Whitepaper, Bitkom, 2011
- [BK21] BAARS, H.; KEMPER, H.-G.: Business Intelligence & Analytics – Grundlagen und praktische Anwendungen. Springer Fachmedien Wiesbaden, Wiesbaden, 2021

- [BLA+21] BOUSDEKIS, A.; LEPENIOTI, K.; APOSTOLOU, D.; MENTZAS, G.: A Review of Data-Driven Decision-Making Methods for Industry 4.0 Maintenance Applications. *Electronics*, (10)7, 2021, S. 828
- [BLB+23] BROCK, J.; LÖHR, B.; BRENNIG, K.; SEGER, T.; BARTELHEIMER, C.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: A process mining maturity model: Enabling organizations to assess and improve their process mining activities. *ECIS 2023 Research Papers*, (256), 2023
- [BLJ23] BOZHDARAJ, D.; LUCKE, D.; JOOSTE, J. L.: Smart Maintenance Architecture for Automated Guided Vehicles. *Procedia CIRP*, (118), 2023, S. 110–115
- [BMM+06] BRANKE, J.; MNIF, M.; MÜLLER-SCHLOER, C.; PROTHMANN, H.; RICHTER, U.; ROCHNER, F.; SCHMECK, H.: Organic Computing - Addressing Complexity by Controlled Self-Organization: Second International Symposium on Leveraging Applications of Formal Methods, Verification and Validation (isola 2006). *Second International Symposium on Leveraging Applications of Formal Methods, Verification and Validation (isola 2006)*, 15.11.2006 - 19.11.2006, Paphos, Cyprus, IEEE, 2006, S. 185–191
- [BMW16] BMWI BUNDESMINISTERIUM FÜR WIRTSCHAFT UND ENERGIE/PLATTFORM INDUSTRIE 4.0: Ergebnispapier - Aspekte der Forschungsroadmap in den Anwendungsprozessen, 2016
- [BMW22] BMW TECHNOLOGY SCOUTING: BMW Trendradar. Unter: <https://www.bmwgroup.com/en/innovation/company/technology-trend-radar.html>, 6. August 2023
- [BPM+20] BOUSDEKIS, A.; PAPAGEORGIOU, N.; MAGOUTAS, B.; APOSTOLOU, D.; MENTZAS, G.: Sensor-driven Learning of Time-Dependent Parameters for Prescriptive Analytics. *IEEE Access*, (Volume 8), 2020, S. 92383–92392
- [BPR+15] BISCHHOFFSHAUSEN, J. K. VON; PAATSCH, M.; REUTER, M.; SATZGER, G.; FROMM, H.: An Information System for Sales Team Assignments Utilizing Predictive and Prescriptive Analytics: 2015 IEEE 17th Conference on Business Informatics. *2015 IEEE 17th Conference on Business Informatics (CBI)*, 13/07/2015 - 16/07/2015, Lisbon, Portugal, IEEE, 2015, S. 68–76
- [BRE+23] BROCK, J.; REMPE, N.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: A Framework For The Domain-Driven Utilization Of Manufacturing Sensor Data In Process Mining: An Action Design Approach. Hannover publish-Ing, 2023
- [Bre06] BREEN, R. L.: A Practical Guide to Focus-Group Research. *Journal of Geography in Higher Education*, (30)3, 2006, S. 463–475

- [BRH+20] BEHAM, A.; RAGGL, S.; HAUDER, V. A.; KARDER, J.; WAGNER, S.; AFFENZELLER, M.: Performance, Quality, and Control in Steel Logistics 4.0. *Procedia Manufacturing*, (42), 2020, S. 429–433
- [Bri96] BRINKKEMPER, S.: Method engineering: engineering of information systems development methods and tools. *Information and Software Technology*, (38)4, 1996, S. 275–280
- [Bro25] BROCK, J.: Systematik zur Leistungssteigerung von Fertigungsprozessen durch Process Mining – Dissertation. HNI Verlagsschriftenreihe, 2025
- [Bru17] BRUNNER, F. J.: Japanische Erfolgskonzepte – KAIZEN, KVP, Lean Production Management, Total Productive Maintenance, Shopfloor Management, Toyota Production System, GD<sup>3</sup>-Lean Development. 4. Auflage, Praxisreihe Qualitätswissen, Hanser, München, 2017
- [BS24-ol] BEAUVOIR, P.; SARRODIE, J.-B.: Archi - ArchiMate Modelling (website) – ArchiMate is a registered Trademark of the Open Group. Unter: <https://www.archimatetool.com/>, 9. September 2025
- [BSJ+18] BAUER, N.; STANKIEWICZ, L.; JASTROW, M.; HORN, D.; TEUBNER, J.; KERSTING, K.; DEUSE, J.; WEIHS, C.: Industrial Data Science: Developing a Qualification Concept for Machine Learning in Industrial Production. KIT Scientific Publishing, (Vol. 5, No. 1, 2018), 2018
- [BSK+15] BRODSKY, A.; SHAO, G.; KRISHNAMOORTHY, M.; NARAYANAN, A.; MENASCE, D.; AK, R.: Analysis and optimization in smart manufacturing based on a reusable knowledge base for process performance models: 2015 IEEE International Conference on Big Data (Big Data). 2015 IEEE International Conference on Big Data (Big Data), 29.10.2015 - 01.11.2015, Santa Clara, CA, USA, IEEE, 2015, S. 1418–1427
- [BSS23] BOKRANTZ, J.; SUBRAMANIYAN, M.; SKOOGH, A.: Realising the promises of artificial intelligence in manufacturing by enhancing CRISP-DM. *Production Planning & Control - The Management of Operations*, 2023, S. 1–21
- [BUB16] BECKER, W.; ULRICH, P.; BOTZKOWSKI, T.: Data Analytics im Mittelstand. *Management und Controlling im Mittelstand*, 2016
- [BVS+16] BOGNER, E.; VOELKLEIN, T.; SCHROEDEL, O.; FRANKE, J.: Study Based Analysis on the Current Digitalization Degree in the Manufacturing Industry in Germany. *Procedia CIRP*, (57), 2016, S. 14–19
- [BWS23] BUIJSSE, R.; WILLEMSEN, M.; SNIJDERS, C.: Data-Driven Decision-Making. In: Liebregts, W.; van Heuvel, W.-J. den; van Born, A. den (Eds.): *Data Science for Entrepreneurship – Principles and Methods for Data Engineering, Analytics, Entrepreneurship, and the Society. Classroom Companion*, Springer International Publishing; Imprint Springer, Cham, 2023, pp. 239–277

- [Byr17] BYRNE, C.: Development Workflows for Data Scientists – Enabling Fast, Efficient, and Reproducible Results for Data Science Teams. O’Reilly Media, 2017
- [Cao18] CAO, L.: Data Science. *ACM Computing Surveys*, (50)3, 2018, S. 1–42
- [CBJ20] CHOUBEY, S.; BENTON, R. G.; JOHNSTEN, T.: A Holistic End-to-End Prescriptive Maintenance Framework. *Data-Enabled Discovery and Applications*, (4)1, 2020
- [CDK23-ol] CRIVETI, M.; DIB, W.; KIRBY, C.: IBM - Generative AI Capability Model, 2023
- [CGM+16] COLEMAN, S.; GÖB, R.; MANCO, G.; PIEVATOLO, A.; TORT-MARTORELL, X.; REIS, M. S.: How Can SMEs Benefit from Big Data? Challenges and a Path Forward. *Quality and Reliability Engineering International*, (32)6, 2016, S. 2151–2164
- [CJS98] CHOUIKHA, M.; JANHSEN, A.; SCHNIEDER, E.: Klassifikation und Bewertung von Beschreibungsmitteln für die Automatisierungstechnik. *at - Automatisierungstechnik*, (46)12, 1998, S. 582–591
- [CLR+19] CHATTI, S.; LAPERRIÈRE, L.; REINHART, G.; TOLIO, T.: *CIRP Encyclopedia of Production Engineering*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2019
- [CLX+22] CHEN, H.; LIU, R.; XIE, Z.; HU, Q.; DAI, J.; ZHAI, J.: Majorities help minorities: Hierarchical structure guided transfer learning for few-shot fault recognition. *Pattern Recognition*, (123), 2022, S. 108383
- [Coc99] COCKBURN, A.: *Writing Effective Use Cases*. Humans and Technology in preparation for Addison-Wesley Longman, Q3 2000., 1999
- [Col12] COLLIER, K.: *Agile analytics – A value-driven approach to business intelligence and data warehousing*. Addison-Wesley, Upper Saddle River, NJ, 2012
- [Cor19] COREA, F.: *An Introduction to Data*. *Studies in Big Data*, (50), 2019
- [CSR+19] CROWSTON, K.; SALTZ, J. S.; REZGUI, A.; HEGDE, Y.; YOU, S.: Socio-technical Affordances for Stigmergic Coordination Implemented in MIDST, a Tool for Data-Science Teams. *Proceedings of the ACM on Human-Computer Interaction*, (3)CSCW, 2019, S. 1–25
- [CWK23] CIEPLY, J.; WEGEL, A.; KÜHN, A.: Methoden für die Gestaltung der Unternehmensarchitektur produzierender Unternehmen – EAM als Enabler für die Konzipierung übertragbarer KI-Lösungen. *I40M (Industrie 4.0 Management) - Künstliche Intelligenz*, 1, 2023, S. 37–42
- [DAG13] DUMITRESCU, R.; ANACKER, H.; GAUSEMEIER, J.: Design framework for the integration of cognitive functions into intelligent technical systems. *Production Engineering*, (7)1, 2013, S. 111–121

- [Das13] DAS, S.: Maintenance Action Recommendation Using Collaborative Filtering. *International Journal of Prognostics and Health Management*, (4)2, 2013
- [DB15] DUTTA, D.; BOSE, I.: Managing a Big Data project: The case of Ramco Cements Limited. *International Journal of Production Economics*, (165), 2015, S. 293–306
- [DCC+15] DAS, M.; CUI, R.; CAMPBELL, D. R.; AGRAWAL, G.; RAMNATH, R.: Towards methods for systematic research on big data: 2015 IEEE International Conference on Big Data (Big Data). 2015 IEEE International Conference on Big Data (Big Data), 29.10.2015 - 01.11.2015, Santa Clara, CA, USA, IEEE, 2015, S. 2072–2081
- [DD21] DUAN, L.; DA XU, L.: Data Analytics in Industry 4.0: A Survey. *Information systems frontiers a journal of research and innovation*, 2021, S. 1–17
- [DD23] DATAIKU; DATABRICKS: AI, Today SURVEY REPORT – Insights From 400 Senior AI Professionals on generative AI, ROI, Tech Stack, & More, 2023
- [DDV18] DIN; DKE; VDE: DEUTSCHE NORMUNGSROADMAP Industrie 4.0 – Version 3, 2018
- [DEG+20] DIEMER, J.; ELMER, S.; GAERTLER, M.; GAMER, T.; GÖRG, C.; GROTEPASS, J.; KALHOFF, J.; KRAMER, S.; LEGAT, C.; MEYER-KAHLEN, J.-P.; NETTSTRÄTER, A.; NIEHÖRSTER, O.; SCHMIDT, B.; SCHWEICHHART, K.; ULRICH, M.; WEITSCHAT, R.; WINTER, J.: KI in der Industrie 4.0: Orientierung, Anwendungsbeispiele, Handlungsempfehlungen. *Wegweiser Industrie 4.0*, 2020
- [Del16] DELOITTE: Manufacturing 4.0: Meilenstein, Must-Have oder Millionengrab? – Warum bei M4.0 die Integration den entscheidenden Unterschied macht, 2016
- [DGK+15] DUMITRESCU, R.; GAUSEMEIER, J.; KÜHN, A.; LUCKEY, M.; PLASS, C.; SCHNEIDER, M.; WESTERMANN, T.: Auf dem Weg zur Industrie 4.0 – Erfolgsfaktor Referenzarchitektur. *it's OWL Clustermanagement*, Paderborn, 2015
- [Die16] DIETRICH, D.: Data analytics lifecycle processes – US Patent 9,262,493 (Feb. 16 2016), 2016
- [DIN22989] DIN EN ISO/IEC 22989 – Informationstechnik – Künstliche Intelligenz - Konzepte und Terminologie der Künstlichen Intelligenz, 2023
- [DIN62264-6] EN IEC 62264-6:2022 - Integration von Unternehmensführungs- und Leitsystemen – Teil 6: Dienstmodell zur Nachrichtenübermittlung, 2022
- [DIN91345] DIN SPEC 91345:2016-04, Reference Architecture Model Industrie 4.0 (RAMI4.0) English translation of DIN SPEC 91345:2016-04, 2016

- [DKM89] DANGELMEIER, W.; KÜHNLE, H.; MUßMACH-WINTER, U.: KI-Einsatz in PPS-Systemen kann nur begrenzt sinnvoll sein – Zur Planungsunterstützung keine "intelligente" Software nötig. Unter: <https://www.computerwoche.de/a/ki-einsatz-in-pps-systemen-kann-nur-begrenzt-sinnvoll-sein,1152639>, 28. Oktober 2025
- [Dom23] DOMINO: Domino Enterprise MLOps Whitepaper - Final. Whitepaper, 2023
- [DP22] DIVYASHREE, N. M.; PRASAD, N.: Design and Development of We-CDSS Using Django Framework: Conducing Predictive and Prescriptive Analytics for Coronary Artery Disease. IEEE Access, (10), 2022, S. 119575–119592
- [DPM+23] DAIM, T.U.; PHAAL, R.; MEISSNER, D.; KERR, C. (Eds.): Next Generation Roadmapping – Establishing Technology and Innovation Pathways Towards Sustainable Value. Springer International Publishing; Imprint Springer, Cham, 2023
- [Dud24-ol] DUDEN: Duden - Definition der Integration. Unter: <https://www.duden.de/>, 4. März 2025
- [Dum10] DUMITRESCU, R.: Entwicklungssystematik zur Integration kognitiver Funktionen in fortgeschrittene mechatronische Systeme. HNI Verlagsschriftenreihe, 2010
- [DWS22] DEUSE, J.; WEST, N.; SYBERG, M.: Rediscovering scientific management. The evolution from industrial engineering to industrial data science. International Journal of Production Management and Engineering, (10)1, 2022, S. 1–12
- [Ehr09] EHRENSPIEL, K.: Integrierte Produktentwicklung – Denkabläufe, Methodeneinsatz, Zusammenarbeit. 4. Auflage, Hanser, München, 2009
- [ELM+22] ELBASHEER, M.; LONGO, F.; MIRABELLI, G.; PADOVANO, A.; SOLINA, V.; TALARICO, S.: Integrated Prescriptive Maintenance and Production Planning: a Machine Learning Approach for the Development of an Autonomous Decision Support Agent. IFAC-PapersOnLine, (55)10, 2022, S. 2605–2610
- [ENM+20] ENZBERG, S. VON; NASKOS, A.; METAXA, I.; KÖCHLING, D.; KÜHN, A.: Implementation and Transfer of Predictive Analytics for Smart Maintenance: A Case Study. Frontiers in Computer Science, (2), 2020
- [Enz22] ENZBERG, S. VON: VIP4PAPS – Flexibilisierung und Effizienzsteigerung in der Smart Factory für KMU. Unter: <https://www.validierungsfoerderung.de/validierungsprojekte/vip4paps>, 6. August 2023
- [ER18] EDWARDS, J. S.; RODRIGUEZ, E.: Analytics and knowledge management - Chapter 1 – Knowledge Management for Action-Oriented Analytics. CRC Press Taylor & Francis Group, Boca Raton, 2018

- [ESM+21] EHRLINGER, L.; SCHROTT, J.; MELICHAR, M.; KIRCHMAYR, N.; WÖB, W.: Data Catalogs: A Systematic Literature Review and Guidelines to Implementation. In: Kotsis, G.; Tjoa, A. M.; Khalil, I.; Moser, B.; Mashkoo, A.; Sametinger, J.; Fensel, A.; Martinez-Gil, J.; Fischer, L.; Czech, G.; Sobieczky, F.; Khan, S. (Eds.): Database and Expert Systems Applications - DEXA 2021 Workshops – BIODDD, IWCFS, MLKgraphs, AI-CARES, ProTime, AISys 2021, Virtual Event, September 27–30, 2021, Proceedings. Communications in Computer and Information Science, 1479, Springer International Publishing; Imprint Springer, Cham, 2021, pp. 148–158
- [EWB+24] ENZBERG, S. VON; WELLER, J.; BROCK, J.; MERKELBACH, S.; PANZNER, M.; LICK, J.; KÜHN, A.; DUMITRESCU, R.: On the Current State of Industrial Data Science: Challenges, Best Practices, and Future Directions. *Procedia CIRP, CIRP CMS*, (130), 2024, S. 1454–1461
- [EWP+24] ENZBERG, S. VON; WELLER, J.; PÖHLER, P.; KÜHN, A.; RÖMER, M.; DUMITRESCU, R.: Künstliche Intelligenz in der Produktionsplanung und -steuerung. *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, (119)5, 2024, S. 349–355
- [Fah95] FAHRWINKEL, U.: Methoden zur Modellierung und Analyse von Geschäftsprozessen zur Unterstützung des Business Process Reengineering – Dissertation. Fachbereich für Maschinentechnik, Universität Paderborn, HNI-Verlagsschriftenreihe, Band 1, Paderborn, 1995
- [Fay96] FAYYAD, U.: From Data Mining to Knowledge Discovery in Databases. *AI Magazine*, 17(3), 1996
- [FBH23] FILZ, M.-A.; BOSSE, J. P.; HERRMANN, C.: Digitalization platform for data-driven quality management in multi-stage manufacturing systems. *Journal of Intelligent Manufacturing*, 2023
- [FCC+23] FORTOUL-DIAZ, J. A.; CARRILLO-MARTINEZ, L. A.; CENTENO-TELLEZ, A.; CORTES-SANTACRUZ, F.; OLMOS-PINEDA, I.; FLORES-QUINTERO, R. R.: A Smart Factory Architecture Based on Industry 4.0 Technologies: Open-Source Software Implementation. *IEEE Access*, (11), 2023, S. 101727–101749
- [FCW+21] FAN, C.; CHEN, M.; WANG, X.; WANG, J.; HUANG, B.: A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data. *Frontiers in Energy Research*, (9), 2021
- [FDA19] FRANK, A. G.; DALENOGARE, L. S.; AYALA, N. F.: Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, (210), 2019, S. 15–26

- [FFL+22] FRIEDERICH, J.; FRANCIS, D. P.; LAZAROVA-MOLNAR, S.; MOHAMED, N.: A framework for data-driven digital twins of smart manufacturing systems. *Computers in Industry*, (136), 2022, S. 103586
- [FHH+23] FARBIZ, F.; HABIBULLAH, M. S.; HAMADICHAREF, B.; MASZCZYK, T.; AGGARWAL, S.: Knowledge-embedded machine learning and its applications in smart manufacturing. *Journal of Intelligent Manufacturing*, (34)7, 2023, S. 2889–2906
- [FK21] FAISAL, A. M.; KARTHIGEYAN, L.: Data Analytics based Prescriptive Analytics for Selection of Lean Manufacturing System. *Proceedings of the 6th International Conference on Inventive Computation Technologies, ICICT 2021*, 2021
- [FKF+16] FLEISCHMANN, H.; KOHL, J.; FRANKE, J.; REIDT, A.; DUCHON, M.; KRCMAR, H.: Improving maintenance processes with distributed monitoring systems: *IEEE 14th International Conference 2016*, 2016, S. 377–382
- [FMB+20] FREDRIKSSON, T.; MATTOS, D. I.; BOSCH, J.; OLSSON, H. H.: Data Labeling: An Empirical Investigation into Industrial Challenges and Mitigation Strategies. *PRODUCT-FOCUSED SOFTWARE PROCESS IMPROVEMENT*, (12562), 2020, S. 202–216
- [FMS12] FRIEDENTHAL, S.; MOORE, A.; STEINER, R.: *A Practical Guide to SysML*. Elsevier, 2012
- [FNP+19] FRAZZETTO, D.; NIELSEN, T. D.; PEDERSEN, T. B.; ŠIKŠNYS, L.: Prescriptive analytics: a survey of emerging trends and technologies. *The VLDB Journal*, (28)4, 2019, S. 575–595
- [Fra06] FRANK, U.: *Spezifikationstechnik zur Beschreibung der Prinziplösung selbstoptimierender Systeme – Dissertation*, Fakultät für Maschinenbau. Dissertation, Band 175. HNI Verlagsschriftenreihe, 2006
- [FSZ21] FINK, H.; SAUTER, R.; ZIRKELBACH, T.: *CxO Priorities Study 2021*. Horváth, Stuttgart, 2021
- [GA11] GALSTER, M.; AVGERIOU, P.: Empirically-grounded reference architectures. In: Crnkovic, I.; Stafford, J. A.; Petriu, D.; Happe, J.; Inverardi, P. (Hrsg.): *Proceedings of the joint ACM SIGSOFT conference -- QoSA and ACM SIGSOFT symposium -- ISARCS on Quality of software architectures -- QoSA and architecting critical systems -- ISARCS. Comparch '11: Federated Events on Component-Based Software Engineering and Software Architecture*, 20 06 2011 24 06 2011, Boulder Colorado USA, ACM, New York, NY, USA, 2011, S. 153–158
- [GAM24] GERUSSI, S.; ANGEHRN, D.; MEENTKEN, F.: *The State of Enterprise Architecture 2024*. Whitepaper BOC Group, 2024
- [Gar22a] GARTNER: *When to Augment Decisions With Artificial Intelligence – Guides for Effective Business Decision Making*. Guide 3 of 5, 2022

- [Gar22b] GARTNER: Gartner Hyper Cycle - Business Analytics Hype Cycle 2022 and 2019. Unter: <https://www.gartner.com/en/newsroom/press-releases/2019-10-02-gartner-reveals-five-major-trends-shaping-the-evoluti>, 9. September 2025
- [GBB+23] GABRIEL, S.; BENTLER, D.; BANSMANN, M.; ANDREW LATOS, B.; KÜHN, A.; DUMITRESCU, R.: Soziotechnische Gestaltung einer intelligenten Personaleinsatzplanung. *Zeitschrift für wirtschaftlichen Fabrikbetrieb*, (118)1-2, 2023, S. 64–68
- [GBG+19] GYULAI, D.; BERGMANN, J.; GALLINA, V.; GAAL, A.: Towards a connected factory: Shop-floor data analytics in cyber-physical environments. *Procedia CIRP*, (86), 2019, S. 37–42
- [GBM24] GARCÍA, Á.; BREGON, A.; MARTÍNEZ-PRIETO, M. A.: Digital Twin Learning Ecosystem: A cyber-physical framework to integrate human-machine knowledge in traditional manufacturing. *Internet of Things*, (25), 2024, S. 101094
- [GBW22] GEISSBAUER, R.; BRUNS, M.; WUNDERLIN, J.: PwC Digital Factory Transformation Survey – Digital backbone, use cases and technologies, organizational setup, strategy and roadmap, investment focus, 2022
- [GDE+19] GAUSEMEIER, J.; DUMITRESCU, R.; ECHTERFELD, J.; PFÄNDER, T.; STEFFEN, D.; THIELEMANN, F.: Innovationen für die Märkte von morgen – Strategische Planung von Produkten, Dienstleistungen und Geschäftsmodellen. Hanser, München, 2019
- [GEK01] GAUSEMEIER, J.; EBBESMEYER, P.; KALLMEYER, F.: Produktinnovation – Strategische Planung und Entwicklung der Produkte von morgen. Hanser, München, 2001
- [GFG+24] GABRIEL, S.; FALKOWSKI, T.; GRAUNKE, J.; DUMITRESCU, R.; MURRENHOF, A.; KRETSCHMER, V.; HOMPEL, M. TEN: Künstliche Intelligenz und industrielle Arbeit – Perspektiven und Gestaltungsoptionen – Expertise des Forschungsbeirats Industrie 4.0. Acatech Expertise – Deutsche Akademie der Technikwissenschaften, 2024
- [GGT23] GERHARD, F.; GEBSER, M.; TEPPAN, E. C.: Symbolic Artificial Intelligence Methods for Prescriptive Analytics. In: Vogel-Heuser, B.; Wimmer, M. (Hrsg.): *Digital Transformation – Core technologies and emerging topics from a computer science perspective*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2023, S. 385
- [GKD23] GABRIEL, S.; KÜHN, A.; DUMITRESCU, R.: Strategic planning of the collaboration between humans and artificial intelligence in production. 56th CIRP International Conference on Manufacturing Systems 2023, *Procedia CIRP*, (120), 2023, S. 1309–1314

- [GLL12] GAUSEMEIER, J.; LANZA, G.; LINDEMANN, U. (Hrsg.): Produkte und Produktionssysteme integrativ konzipieren – Modellbildung und Analyse in der frühen Phase der Produktentstehung. Hanser, München, 2012
- [GMH23] GUHA, B.; MOORE, S.; HUYGHE, J. M.: Conceptualizing data-driven closed loop production systems for lean manufacturing of complex bio-medical devices—a cyber-physical system approach. *Journal of Engineering and Applied Science*, (70)1, 2023
- [GN12] GAUSEMEIER, J.; NORDSIEK, D.: Einführung. In: Gausemeier, J.; Lanza, G.; Lindemann, U. (Hrsg.): Produkte und Produktionssysteme integrativ konzipieren – Modellbildung und Analyse in der frühen Phase der Produktentstehung. Hanser, München, 2012
- [GNL23] GONZÁLEZ, A. G.; NIETO, E.; LETURIONDO, U.: A Prescriptive Analysis Tool for Improving Manufacturing Processes. In: Crespo Márquez, A.; Gómez Fernández, J. F.; González-Prida Díaz, V.; Amadi-Echendu, J. (Hrsg.): 16th WCEAM Proceedings. Springer International Publishing, Cham, 2023, S. 283–291
- [Goi19] GOIENETXEA URIARTE, A.: Bringing together Lean, simulation and optimization. – Defining a framework to support decision-making in system design and improvement. Dissertation, Industrial Informatics, University of Skövde, 2019
- [GP14] GAUSEMEIER, J.; PLASS, C.: Zukunftsorientierte Unternehmensgestaltung – Strategien, Geschäftsprozesse und IT-Systeme für die Produktion von morgen. 2. Auflage, Hanser, München, 2014
- [GPP17] GRADY, N.; PAYNE, J.; PARKER, H.: Agile Big Data Analytics – AnalyticsOps for Data Science. *IEEE Access*, 2017
- [Grö18] GRÖGER, C.: Building an Industry 4.0 Analytics Platform. *Datenbank-Spektrum*, (18)1, 2018, S. 5–14
- [Grö22] GRÖGER, C.: Industrial analytics – An overview. *it - Information Technology*, (64)1-2, 2022, S. 55–65
- [GT23] GHASEMAGHAEI, M.; TUREL, O.: The Duality of Big Data in Explaining Decision-Making Quality. *Journal of Computer Information Systems*, (63)5, 2023, S. 1093–1111
- [Guo12] GUO, P. J.: Software tools to facilitate research programming. Ph.D. thesis, Stanford University Stanford, CA, 2012
- [Háj11] HÁJEK, A.: Conditional Probability. *Philosophy of Statistics, Volume 7 in Handbook of the Philosophy of Science*, 2011
- [Han13] HANSCHKE, I.: Strategisches Management der IT-Landschaft – Ein praktischer Leitfaden für das Enterprise Architecture Management. 3. Auflage, Hanser eLibrary, Hanser, München, 2013

- [Hau85] HAUGELAND, J.: Artificial intelligence: The very idea. MIT Press, Cambridge, 1985
- [HBK+24] HARTMANN, S.; BROCK, J.; KÜHN, A.; DUMITRESCU, R.: Applying Artificial Intelligence in the Smart Factory: Lessons Learned from real-world use cases. 57th CIRP Conference on Manufacturing Systems 2024 (CMS 2024), 2024
- [Hei24] HEIHOFF-SCHWEDE, J.: Spezifikationstechnik zur Analyse, Gestaltung und Bewertung von Engineering IT-Architekturen – Dissertation. HNI Verlagsschriftenreihe, 2024
- [Hen20] HENTSCHEL, R.: Developing Design Principles for a Cloud Broker Platform for SMEs: 2020 IEEE 22nd Conference on Business Informatics (CBI). 2020 IEEE 22nd Conference on Business Informatics (CBI), 22/06/2020 - 24/06/2020, Antwerp, Belgium, IEEE, 2020, S. 290–299
- [Hev07] HEVNER, A. R.: A Three Cycle View of Design Science Research: Scandinavian Journal of Information Systems, 2007
- [HFR+99] HAASIS, S.; FRANK, D.; ROMMEL, B.; WEYRICH, M.: Feature-basierte Integration von Produktentwicklung, Prozeßgestaltung und Ressourcenplanung, 1999
- [HHS24] HERF, M.; HAGER, N.; SCHREIBER, T.: INDUSTRY 4.0 BAROMETER 2024 – Study. MHP- a Porsche Company, 2024
- [HJB21] HUBER, M.; JAUCH, C.; BURMEISTER, K.: Potenziale von KI für die Produktion. In: Knappertsbusch, I.; Gondlach, K. (Hrsg.): Arbeitswelt und KI 2030. Springer Fachmedien Wiesbaden, Wiesbaden, 2021
- [HKD20] HEIHOFF-SCHWEDE, J.; KAISER, L.; DUMITRESCU, R.: AN MBSE-BASED APPROACH FOR THE DEFINITION AND EVALUATION OF ENGINEERING IT ARCHITECTURES. Proceedings of the Design Society: DESIGN Conference, (1), 2020, S. 2285–2294
- [HKS+22] HIRSCH-KREINSEN, H.; KUBACH, U.; STARK, R.; WICHERT, G. VON; LITSCHE, S.; SEDLMEIR, J.; STEGLICH, S.: Themenfelder Industrie 4.0 - Forschungs- und Entwicklungsbedarfe für die erfolgreiche Umsetzung von Industrie 4.0. Forschungsbeirat der Plattform Industrie 4.0 / acatech – Deutsche Akademie der Technikwissenschaften, 2022
- [HMK23] HARTMANN, P.; MODIC, D.; KLAUSING, S.: Elements of a Comprehensive AI Strategy – 2nd Edition. Initiative for applied Artificial Intelligence, 2023
- [HMS+23] HOPF, K.; MÜLLER, O.; SHOLLO, A.; THIESS, T.: Organizational Implementation of AI: Craft and Mechanical Work. California Management Review, 2023
- [Hod21] HODLER, A. E.: Artificial Intelligence & Graph Technology – Enhancing AI with Context & Connections. Neo4j Whitepaper, 2021

- [HOS20] HECHLER, E.; OBERHOFER, M.; SCHAECK, T.: Deploying AI in the Enterprise. Apress, Berkeley, CA, 2020
- [HP16] HERTOOG, D. DEN; POSTEK, K.: Bridging the gap between predictive and prescriptive analytics - new optimization methodology needed. Optimization Online, 2016
- [HPO16] HERMANN, M.; PENTEK, T.; OTTO, B.: Design Principles for Industrie 4.0 Scenarios: 2016 49th Hawaii International Conference on System Sciences (HICSS). 2016 49th Hawaii International Conference on System Sciences (HICSS), 05.01.2016 - 08.01.2016, Koloa, HI, USA, IEEE, 2016, S. 3928–3937
- [HRH+23] HERSCHEL, G.; RAMAKRISHNAN, R.; HAMER, P. DEN; CRAIG, T.; SALLAM, R.; CIAVARDINI, L.; CLOUGHERTY JONES, L.; RONTAL, A.; WHITE, A.; JAIN, A.; LITAN, A.; IDOINE, C.; PIDSLEY, D.; FEINBERG, D.; ZAIDI, E.; BRETHENOUX, E.; RIGON, G.; MEDD, J.; SUN, J.; FERGUSON, L.; BEYER, M.; TALWAR, M.; CHIEN, M.; THANARAJ, R.; AGARWAL, S.; SICULAR, S.; O'CALLAGHAN, G.; DUNCAN, A. D.: Top Trends in Data and Analytics 2023 – by Gartner. Unter: <https://www.gartner.com/doc/reprints?id=1-2D5XJT8I&ct=230407&st=sb>, 2. August 2023
- [HSB24-ol] HSBI, CENTER FOR APPLIED DATA SCIENCE: IoT-Factory. Unter: <https://www.hsbi.de/iium/efads/projekte/iot-factory>, 26. März 2024
- [HSN+20] HRIBERNIK, K.; STIETENCRON, M. VON; NTALAPERAS, D.; THOBEN, K.-D.: Unified Predictive Maintenance System - Findings Based on its Initial Deployment in Three Use Case. IFAC-PapersOnLine, (53)3, 2020, S. 191–196
- [HSP+21] HASTEROK, C.; STOMPE, J.; PFROMMER, J.; USLÄNDER, T.; ZIEHN, J.; REITER, S.; WEBER, M.; RIEDEL, T.: PAISE - The process model for AI Systems Engineering. CC-King, Competence Center for AI Systems Engineering, 2021
- [HTP+04] HEVNER, A.; T. MARCH, S.; PARK, J.; RAM, S.: Design Science in Information Systems Research, 2004
- [Hül21] HÜLLERMEIER, E.: Prescriptive Machine Learning for Automated Decision Making: Challenges and Opportunities, 2021
- [HWS+19] HUBER, S.; WIEMER, H.; SCHNEIDER, D.; IHLENFELDT, S.: DMME: Data mining methodology for engineering applications – a holistic extension to the CRISP-DM model. Procedia CIRP, (79), 2019, S. 403–408
- [IBM21] IBM INSTITUTE FOR BUSINESS VALUE: The CIO Revolution – Breaking barriers, creating Value. The 2021 CIO Study, 2021
- [IEC42010] ISO: ISO/IEC/IEEE 42010:2022. INTERNATIONAL STANDARD, 2022

- [IHB+18] ISSA, A.; HATIBOGLU, B.; BILDSTEIN, A.; BAUERNHANSL, T.: Industrie 4.0 roadmap: Framework for digital transformation based on the concepts of capability maturity and alignment. *Procedia CIRP*, (72), 2018, S. 973–978
- [ISO42020] ISO: ISO/IEC/IEEE 42020:2019. INTERNATIONAL STANDARD, 2019
- [JA17] JANI, M.; ALBERTS, M.: Team Data Science Process Documentation – Artificial intelligence (AI) architecture design. Microsoft - Azure Documentation, 2017
- [Jar18] JARRAHI, M. H.: Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, (61)4, 2018, S. 577–586
- [JCL+23] JIN, Z.; CHEN, Y.; LEEB, F.; GRESELE, L.; KAMAL, O.; LYU, Z.; BLIN, K.; ADAUTO, F. G.; KLEIMAN-WEINER, M.; SACHAN, M.; SCHÖLKOPF, B.: CLadder: A Benchmark to Assess Causal Reasoning Capabilities of Language Models, 2023
- [JEG+19] JOPPEN, R.; ENZBERG, S. VON; GUNDLACH, J.; KÜHN, A.; DUMITRESCU, R.: Key performance indicators in the production of the future. *Procedia CIRP*, (81), 2019, S. 759–764
- [JEK+19] JOPPEN, R.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Data map – method for the specification of data flows within production. *Procedia CIRP*, (79), 2019, S. 461–465
- [JG19] JASIULEWICZ-KACZMAREK, M.; GOLA, A.: Maintenance 4.0 Technologies for Sustainable Manufacturing - an Overview. *IFAC-PapersOnLine*, (52)10, 2019, S. 91–96
- [JKB19] JOHN, I.; KARUMANCHI, R.; BHATNAGAR, S.: Predictive and Prescriptive Analytics for Performance Optimization: Framework and a Case Study on a Large-Scale Enterprise System: 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA). 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA), 16.12.2019 - 19.12.2019, Boca Raton, FL, USA, IEEE, 2019, S. 876–881
- [JKF+22] JOPPEN, R.; KÜHN, A.; FÖRSTER, M.; DUMITRESCU, R.: Evaluation of Industry 4.0 Applications in Production. *Journal of the Knowledge Economy*, 2022
- [JLT+19] JOPPEN, R.; LIPSMEIER, A.; TEWES, C.; KÜHN, A.; DUMITRESCU, R.: Evaluation of investments in the digitalization of a production. *Procedia CIRP*, (81), 2019, S. 411–416
- [JO23] JAHNKE, N.; OTTO, B.: Data Catalogs in the Enterprise: Applications and Integration. *Datenbank-Spektrum*, (23)2, 2023, S. 89–96

- [Jop21] JOPPEN, R.: Systematik zur Bewertung von Industrie 4.0 Anwendungen in der Produktion – Dissertation. HNI Verlagsschriftenreihe, 2021
- [JQH16] JIN, Y.; QIN, S. J.; HUANG, Q.: Prescriptive analytics for understanding of out-of-plane deformation in additive manufacturing. 2016 IEEE International Conference on Automation Science and Engineering (CASE), 2016, S. 786–791
- [Jur17] JURNEY, R.: Agile Data Science 2.0: Building Full-Stack Data Analytics Applications with Spark. O’Reilly Media, 2017
- [KA23] KANIAPPAN CHINNATHAI, M.; ALKAN, B.: A digital life-cycle management framework for sustainable smart manufacturing in energy intensive industries. *Journal of Cleaner Production*, (419), 2023, S. 138259
- [KAA+22] KAHVECI, S.; ALKAN, B.; AHMAD, M. H.; AHMAD, B.; HARRISON, R.: An end-to-end big data analytics platform for IoT-enabled smart factories: A case study of battery module assembly system for electric vehicles. *Journal of Manufacturing Systems*, (63), 2022, S. 214–223
- [KAG19] KUZYAKOV, O. N.; ANDREEVA, M. A.; GLUHIH, I. N.: Applying Case-Based Reasoning Method for Decision Making in IIoT System: 2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon). 2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon), 01.10.2019 - 04.10.2019, Vladivostok, Russia, IEEE, 2019, S. 1–6
- [KAT+22] KORSTEN, G.; AYSOLMAZ, B.; TURETKEN, O.; EDEL, D.; OZKAN, B.: ADA-CMM: A Capability Maturity Model for Advanced Data Analytics. In: Bui, T. (Hrsg.): Proceedings of the 55th Hawaii International Conference on System Sciences. Proceedings of the Annual Hawaii International Conference on System Sciences, 2022
- [Kau19] KAUFMANN, M.: Big Data Management Canvas: A Reference Model for Value Creation from Data. *Big data and cognitive computing*, (3)1, 2019, S. 19
- [KC21] KAVITHA, D.; CHINNASAMY, A.: Ai Integration in Data Driven Decision Making for Resource Management in Internet of Things(Iot): A Survey: 2021 10th International Conference on Internet of Everything, Microwave Engineering, Communication and Networks (IEMECON). 2021 10th International Conference on Internet of Everything, Microwave Engineering, Communication and Networks (IEMECON), 01.12.2021 - 02.12.2021, Jaipur, India, IEEE, 2021, S. 1–5
- [KE22] KLEES, M.; EVIRGEN, S.: Building a smart database for predictive maintenance in already implemented manufacturing systems. *Procedia Computer Science*, (204), 2022, S. 14–21

- [Kee92] KEENEY, R. L.: On the Foundations of Prescriptive Decision Analysis. In: Edwards, W. (Ed.): Utility theories: measurements and applications – The Conference on "Utility: Theories, Measurements, and Applications" met at the Inn at Pasatiempo in Santa Cruz, California, from June 11 to 15, 1989. Studies in Risk and Uncertainty, 3, Kluwer Acad. Publ, Boston, Mass., 1992, pp. 57–72
- [KGK23] KARIM, R.; GALAR, D.; KUMAR, U.: AI factory – Theories, applications and case studies. ICT in asset management, CRC Press Taylor & Francis Group, Boca Raton, 2023
- [KGS+24] KIESEL, R.; GÜTZLAFF, A.; SCHMITT, R. H.; SCHUH, G.: Methods and Limits of Data-Based Decision Support in Production Management. In: Brecher, C.; Schuh, G.; van der Aalst, W.; Jarke, M.; Piller, F. T.; Padberg, M. (Hrsg.): Internet of Production. Springer International Publishing, Cham, 2024
- [KHK+20] KIRCHHOF, M.; HAAS, K.; KORNAS, T.; THIEDE, S.; HIRZ, M.; HERRMANN, C.: Root Cause Analysis in Lithium-Ion Battery Production with FMEA-Based Large-Scale Bayesian Network, 2020
- [KJR+18] KÜHN, A.; JOPPEN, R.; REINHART, F.; RÖLTGEN, D.; ENZBERG, S. VON; DUMITRESCU, R.: Analytics Canvas – A Framework for the Design and Specification of Data Analytics Projects. Procedia CIRP, (70), 2018, S. 162–167
- [KK22] KUMARI, M.; KULKARNI, M. S.: Developing a prescriptive decision support system for shop floor control. Industrial Management & Data Systems, (122)8, 2022, S. 1853–1881
- [KKM+20] KULIN, M.; KAZAZ, T.; MOERMAN, I.; POORTER, E. D.: A survey on Machine Learning-based Performance Improvement of Wireless Networks: PHY, MAC and Network layer, 2020
- [KM06] KURGAN, L. A.; MUSILEK, P.: A survey of Knowledge Discovery and Data Mining process models. The Knowledge Engineering Review, (21)1, 2006, S. 1–24
- [KML+19] KOHL, M.; MALIK, B.; LOPITZSCH, J.; FOTTNER, J.: Auswahl- und Priorisierungsmodell für Industrie 4.0-Use Cases in der Logistik. Wissenschaftliche Gesellschaft für Technische Logistik, 2019
- [KNS+23] KUTZ, J.; NEUHÜTTLER, J.; SCHAEFER, K.; SPILSKI, J.; LACHMANN, T.: Generic Role Model for the Systematic Development of Internal AI-based Services in Manufacturing. In: Bui, T. X. (Ed.): Proceedings of the 56th Annual Hawaii International Conference on System Sciences – January 3-6, 2023. Department of IT Management Shidler College of Business University of Hawaii, Honolulu, HI, 2023

- [KPB+09] KITCHENHAM, B.; PEARL BRERETON, O.; BUDGEN, D.; TURNER, M.; BAILEY, J.; LINKMAN, S.: Systematic literature reviews in software engineering – A systematic literature review. *Information and Software Technology*, (51)1, 2009, S. 7–15
- [KR22] KLETTI, J.; RIEGER, J.: Die perfekte Produktion – Manufacturing Excellence in der Smart Factory - 3. Auflage. Springer Fachmedien Wiesbaden, 2022
- [KSM23] KULKARNI, A.; SHIVANANDA, A.; MANURE, A.: Introduction to Prescriptive AI – A Primer for Decision Intelligence Solutioning with Python. Apress; Imprint Apress, Berkeley, CA, 2023
- [KTK+23] KÖDDING, P.; TISSEN, D.; KOLDEWEY, C.; DUMITRESCU, R.: A Data Map for Product Creation: Tasks, Data Flows, and IT-Systems from the Initial Idea to the Start of Production. *Procedia CIRP*, (120), 2023, S. 1095–1100
- [Kur90] KURZWEIL, R.: The age of intelligent machines. MIT Press, Cambridge, Mass., 1990
- [KWH+12] KAGERMANN, H.; WAHLSTER, W.; HELBIG, J.; FORSCHUNGSUNION WIRTSCHAFT - WISSENSCHAFT: Im Fokus: das Zukunftsprojekt Industrie 4.0 ; Handlungsempfehlungen zur Umsetzung ; Bericht der Promotorengruppe Kommunikation. Forschungsunion, 2012
- [Lan17] LANKHORST, M.: Enterprise Architecture at Work – Modelling, Communication and Analysis. Fourth Edition, 2017
- [LBA+20] LEPENIOTI, K.; BOUSDEKIS, A.; APOSTOLOU, D.; MENTZAS, G.: Prescriptive analytics: Literature review and research challenges. *International Journal of Information Management*, (50), 2020, S. 57–70
- [LBA+21] LEPENIOTI, K.; BOUSDEKIS, A.; APOSTOLOU, D.; MENTZAS, G.: Human-Augmented Prescriptive Analytics With Interactive Multi-Objective Reinforcement Learning. *IEEE Access*, (9), 2021, S. 100677–100693
- [LBH+21] LONGARD, L.; BRUNGS, F.; HERTLE, C.; ROETH, J.; METTERNICH, J.: Reduced Rework Through Data Analytics and Machine Learning – A Three Level Development Approach. *SSRN Electronic Journal*, 2021
- [LBH15] LECUN, Y.; BENGIO, Y.; HINTON, G.: Deep learning. *Nature*, (521)7553, 2015, S. 436–444
- [LBM22] LONGARD, L.; BARDY, S.; METTERNICH, J.: Towards a Data-driven Performance Management in Digital Shop Floor Management. Hannover publish-Ing, 2022
- [LC16] LARSON, D.; CHANG, V.: A review and future direction of agile, business intelligence, analytics and data science. *International Journal of Information Management*, (36)5, 2016, S. 700–710

- [LDK+24] LICK, J.; DISSELKAMP, J.-P.; KATTENSTROTH, F.; TRIENENS, M.; RASOR, R.; KÜHN, A.; DUMITRESCU, R.: Digital Factory Twin: A Practitioner-Driven Approach for Integrated Planning of the Enterprise Architecture. *Procedia CIRP*, (128), 2024, S. 603–608
- [Lea24-ol] LEANIX: The Manufacturer’s Guide to Business Capabilities, 2024
- [LFR+21] LISTL, F. G.; FISCHER, J.; ROSEN, R.; SOHR, A.; WEHRSTEDT, J. C.; WEYRICH, M.: Decision Support on the Shop Floor Using Digital Twins. In: Dolgui, A.; Bernard, A.; Lemoine, D.; Cieminski, G. von; Romero, D. (Hrsg.): *Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems. IFIP Advances in Information and Communication Technology*, Springer International Publishing, Cham, 2021, S. 284–292
- [Lip21] LIPSMEIER, A.: *Systematik zur Entwicklung von Digitalisierungsstrategien für Industrieunternehmen – Dissertation*. HNI Verlagsschriftenreihe, 2021
- [LKJ+20] LIPSMEIER, A.; KÜHN, A.; JOPPEN, R.; DUMITRESCU, R.: Process for the development of a digital strategy. *Procedia CIRP*, (88), 2020, S. 173–178
- [LL16] LAUDON, K. C.; LAUDON, J. P.: *Management information systems – Managing the digital firm*. Pearson, Boston, 2016
- [LLE+20] LABADIE, C.; LEGNER, C.; EURICH, M.; FADLER, M.: FAIR Enough? Enhancing the Usage of Enterprise Data with Data Catalogs: 2020 IEEE 22nd Conference on Business Informatics (CBI). 2020 IEEE 22nd Conference on Business Informatics (CBI), 22.06.2020 - 24.06.2020, Antwerp, Belgium, IEEE, 2020, S. 201–210
- [LMK21] LEYBOLD, M.; MARK, M.; KNOEPFEL, C.: *One data strategy to rule them all – A comparative perspective on data strategies*. PwC Switzerland, 2021
- [LP23] LO, V. S. Y.; PACHAMANOVA, D. A.: From Meaningful Data Science to Impactful Decisions: The Importance of Being Causally Prescriptive. *Data Science Journal*, (22), 2023
- [LPB+20] LEPENIOTI, K.; PERTSELAKIS, M.; BOUSDEKIS, A.; LOUCA, A.; LAMPATHAKI, F.; APOSTOLOU, D.; MENTZAS, G.; ANASTASIOU, S.: Machine Learning for Predictive and Prescriptive Analytics of Operational Data in Smart Manufacturing. In: Dupuy-Chessa, S.; Proper, E. (Eds.): *Advanced Information Systems Engineering Workshops – CAiSE 2020 International Workshops*, Grenoble, France, June 8–12, 2020, Proceedings. Springer eBook Collection, 382, Springer International Publishing; Imprint Springer, Cham, 2020, pp. 5–16
- [LPR+23] LUNDBORG, M.; PAPEN, M.-C.; ROLOFF, M.; SIMONS, J. M.; STAMM, P.: *Künstliche Intelligenz im Mittelstand – Mit welchen Anwendungen sind*

- kleine und mittlere Unternehmen heute schon erfolgreich? - Eine Erhebung der Mittelstand-Digital Begleitforschung im Auftrag des Bundesministeriums für Wirtschaft und Klimaschutz, 2023
- [LS24] LANGER, B.; SCHIRRMACHER, V.: Towards a Canvas for Defining and Structuring Analytics Projects. In: Li, S. (Hrsg.): Information Management. Band 2102, Springer Nature Switzerland, Cham, 2024, C1-C1
- [LSR+19] LECHEVALIER, D.; SHIN, S.-J.; RACHURI, S.; FOUFOU, S.; LEE, Y. T.; BOURAS, A.: Simulating a Virtual Machining Model in an Agent-Based Model for Advanced Analytics. *Journal of intelligent manufacturing*, (30), 2019
- [LTC+15] LI, J.; TAO, F.; CHENG, Y.; ZHAO, L.: Big Data in product lifecycle management. *The International Journal of Advanced Manufacturing Technology*, (81)1-4, 2015, S. 667–684
- [LWB+24] LICK, J.; WELLER, J.; BROCK, J.; PATHAK, S.; DISSELKAMP, J.-P.; KÜHN, A.; DUMITRESCU, R.: Guiding The Transformation To A Digital Factory Twin: Towards An Enterprise-Architecture-Management-based Approach With The Help Of A Capability Map. *Procedia CIRP*, (130), 2024, S. 736–742
- [LWK23] LICK, J.; WEGEL, A.; KÜHN, A.: Methods for Designing Enterprise Architecture in Manufacturing Companies - EAM as Enabler for the Design of Transferable AI Solutions. *Industry 4.0 Science*, (2023)1, 2023
- [LYH+19] LU, J.; YAN, Z.; HAN, J.; ZHANG, G.: Data-Driven Decision-Making (D<sup>3</sup>M): Framework, Methodology, and Directions. *IEEE Transactions on Emerging Topics in Computational Intelligence*, (3)4, 2019, S. 286–296
- [Mat05] MATHESON, J. E.: Decision Analysis = Decision Engineering. In: Greenberg, H. J.; Smith, J. C. (Hrsg.): *Emerging Theory, Methods, and Applications*. INFORMS, 2005, S. 195–212
- [Mat11] MATTHES, D.: *Enterprise Architecture Frameworks Kompendium*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2011
- [Maz20] MAZAROV, J., SCHMITT, J., DEUSE, J., RICHTER, R., KÜHNAST-BENEDIKT, R., & BIEDERMANN, H.: Visualisierung in industrial Data Science-Projekten. *Industrie 4.0 Management*, 36 (6), 2020, S. 63–66
- [MBC+19] MEISTER, M.; BEBLE, J.; CVIKO, A.; BÖING, T.; METTERNICH, J.: Manufacturing Analytics for problem-solving processes in production. *Procedia CIRP*, (81), 2019, S. 1–6
- [MBD+90] MITCHELL, T.; BUCHANAN, B.; DEJONG, G.; DIETTERICH, T.; ROSENBLUM, P.; WAIBEL, A.: Machine Learning. *Annual Review of Computer Science*, (4)1, 1990, S. 417–433
- [McC24] MCCAULEY, D.: Taking AI to the next level in manufacturing. MIT Technology Review Insights in cooperation with Microsoft, 2024

- [MEK+22] MERKELBACH, S.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Towards a Process Model to Enable Domain Experts to Become Citizen Data Scientists for Industrial Applications: 2022 IEEE 5th International Conference on Industrial Cyber-Physical Systems (ICPS). 24.05.2022 - 26.05.2022, Coventry, United Kingdom, IEEE, 2022, S. 1–6
- [Mer16] MERZ, S. L.: Industrie 4.0 – Vorgehensmodell für die Einführung. In: Roth, A. (Hrsg.): Einführung und Umsetzung von Industrie 4.0 – Grundlagen, Vorgehensmodell und Use Cases aus der Praxis. Springer Gabler, Berlin, 2016
- [MF10] MATTERN, F.; FLÖRKEMEIER, C.: Vom Internet der Computer zum Internet der Dinge. Informatik-Spektrum, Vol. 33, No. 2/210, 2010
- [MFK+22] MEYER, M.; FICHTLER, T.; KOLDEWEY, C.; DUMITRESCU, R.: Potentials and challenges of analyzing use phase data in product planning of manufacturing companies. Artificial Intelligence for Engineering Design, Analysis and Manufacturing, (36), 2022
- [MGO20] MÖLLER, F.; GUGGENBERGER, T. M.; OTTO, B.: Towards a Method for Design Principle Development in Information Systems. In: Hofmann, S.; Müller, O.; Rossi, M. (Hrsg.): Designing for Digital Transformation. Co-Creating Services with Citizens and Industry. Lecture Notes in Computer Science, Springer International Publishing, Cham, 2020, S. 208–220
- [MHB23] MALBURG, L.; HOFFMANN, M.; BERGMANN, R.: Applying MAPE-K control loops for adaptive workflow management in smart factories. Journal of Intelligent Information Systems, (61)1, 2023, S. 83–111
- [MHD22] MEISTER, F.; HOHMANN, A.; DAUB, R.: Digitales Shopfloor Management – Datenbasierte Prozessoptimierung mittels Kombination aus Process Mining und Case-based Reasoning. Zeitschrift für wirtschaftlichen Fabrikbetrieb, (117)3, 2022, S. 122–127
- [MJ01] MOYLE, S.; JORGE, A.: RAMSYS-A methodology for supporting rapid remote collaborative data mining projects. Decision Support and Meta Learning IDDM-2001, 2001
- [MKD23] MEISTER, F.; KHANAL, P.; DAUB, R.: Digital-supported problem solving for shopfloor steering using case-based reasoning and Bayesian networks. Procedia CIRP, (119), 2023, S. 140–145
- [MKL+19] MENEZES, B. C.; KELLY, J. D.; LEAL, A. G.; LE ROUX, G. C.: Predictive, Prescriptive and Detective Analytics for Smart Manufacturing in the Information Age. IFAC-PapersOnLine, (52)1, 2019, S. 568–573
- [MKM+19] MAYR, A.; KIBKALT, D.; MEINERS, M.; LUTZ, B.; SCHÄFER, F.; SEIDEL, R.; SELMAIER, A.; FUCHS, J.; METZNER, M.; BLANK, A.; FRANKE, J.: Machine Learning in Production – Potentials, Challenges and Exemplary Applications. Procedia CIRP, (86), 2019, S. 49–54

- [MMB+22] MÜNCH, C.; MARX, E.; BENZ, L.; HARTMANN, E.; MATZNER, M.: Capabilities of digital servitization: Evidence from the socio-technical systems theory. *Technological Forecasting and Social Change*, (176), 2022, S. 121361
- [MMF+20] MASSMANN, M.; MEYER, M.; FRANK, M.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Method for data inventory and classification. *Procedia CIRP*, (93), 2020, S. 234–239
- [MMM20] MATENGA, A.; MURENA, E.; MPOFU, K.: Prescriptive Modelling System Design for an Armature Multi-coil Rewinding Cobot Machine. *Procedia CIRP*, (91), 2020, S. 284–289
- [MMO+20] MADRID, M. C. R.; MALAKI, E. G.; ONG, P. L. S.; SOLOMO, M. V. S.; SUNTAY, R. A. L.; VICENTE, H. N.: Healthcare Management System with Sales Analytics using Autoregressive Integrated Moving Average and Google Vision: 2020 IEEE 12th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM). 2020 IEEE 12th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), 03/12/2020 - 07/12/2020, Manila, Philippines, IEEE, 2020, S. 1–6
- [MN07] MYERS, M. D.; NEWMAN, M.: The qualitative interview in IS research: Examining the craft. *Information and Organization*, (17)1, 2007, S. 2–26
- [MN09] MOEN, R.; NORMAN, C.: Evolution of the PDCA Cycle. *Proceedings of the 7th ANQ Congress*, Tokyo, 2009
- [MNK+17] MATYAS, K.; NEMETH, T.; KOVACS, K.; GLAWAR, R.: A procedural approach for realizing prescriptive maintenance planning in manufacturing industries. *CIRP Annals*, (66)1, 2017, S. 461–464
- [Moc21] MOCKENHAUPT, A.: *Digitalisierung und Künstliche Intelligenz in der Produktion*. Springer Fachmedien Wiesbaden, Wiesbaden, 2021
- [MPH18] MUSTAFEE, N.; POWELL, J. H.; HARPER, A.: RH-RT: A DATA ANALYTICS FRAMEWORK FOR REDUCING WAIT TIME AT EMERGENCY DEPARTMENTS AND CENTRES FOR URGENT CARE: 2018 Winter Simulation Conference (WSC). 2018 Winter Simulation Conference (WSC), 09/12/2018 - 12/12/2018, Gothenburg, Sweden, IEEE, 2018, S. 100–110
- [MPK+21] MEYER, M.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: Towards Identifying Data Analytics Use Cases in Product Planning. *Procedia CIRP*, (104), 2021, S. 1179–1184
- [MPM17] MEUDT, T.; POHL, M.; METTERNICH, J.: *Die Automatisierungspyramide - Ein Literaturüberblick*. Prozesslernfabrik Darmstadt, 2017

- [MS23] MOHAN, S. P.; S, J. N.: A prescriptive analytics approach for tool wear monitoring using machine learning techniques. 2023 Third International Conference on Secure Cyber Computing and Communication (ICSCCC), 2023, S. 228–233
- [MS95] MARCH, S. T.; SMITH, G. F.: Design and natural science research on information technology. Decision Support Systems, 1995
- [MSM+08] MARBÁN, O.; SEGOVIA, J.; MENASALVAS, E.; FERNÁNDEZ-BAIZÁN, C.: Toward data mining engineering: A software engineering approach. Elsevier, 2008
- [MSM+11] MENZ, M.; SCHMID, T.; MÜLLER-STEWENS, G.; LECHNER, C.: Strategische Initiativen und Programme – Unternehmen gezielt transformieren. Uniscope. Publikationen der SGO Stiftung, Gabler, Wiesbaden, 2011
- [MVO21] MARTINEZ, I.; VILES, E.; OLAIZOLA, I. G.: Data Science Methodologies: Current Challenges and Future Approaches. Big Data Research, (24)3, 2021, S. 100183
- [MWJ+21] MA, J.; WANG, Q.; JIANG, Z.; ZHAO, Z.: A hybrid modeling methodology for cyber physical production systems: framework and key techniques. Production Engineering, (15)6, 2021, S. 773–790
- [MWK+18] MAYR, A.; WEIGELT, M.; KÜHL, A.; GRIMM, S.; ERLI, A.; POTZEL, M.; FRANKE, J.: Lean 4.0 - A conceptual conjunction of lean management and Industry 4.0. Procedia CIRP, (72), 2018, S. 622–628
- [MWP+22] MEYER, M.; WIEDERKEHR, I.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: A Reference Process Model for Usage Data-Driven Product Planning, 2022
- [MWS+19] MAZAROV, J.; WOLF, P.; SCHALLOW, J.; NÖHRING, F.; DEUSE, J.; RICHTER, R.: Industrial Data Science in Wertschöpfungsnetzwerken. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb, (114)12, 2019, S. 874–877
- [NHQ+17] NYHUIS, P.; HÜBNER, M.; QUIRICO, M.; SCHÄFERS, P.; SCHMIDT, M.: Veränderung in der Produktionsplanung und -steuerung. In: Reinhart, G. (Hrsg.): Handbuch Industrie 4.0 – Geschäftsmodelle, Prozesse, Technik. Hanser eLibrary, Carl Hanser Verlag, München, 2017, S. 31–50
- [Nic18] NICHOLAS J HOTZ, JEFFREY SALTZ: Domino Data Science Lifecycle – Data Science Project Management. Domino, 2018
- [NMW+24] NIEDERHAUS, M.; MIGENDA, N.; WELLER, J.; SCHENCK, W.; KOHLHASE, M.: Technical Readiness of Prescriptive Analytics Platforms: A Survey. 35th FRUCT conference - Open Innovations Association FRUCT, 2024, S. 509–519
- [NMW+25] NIEDERHAUS, M.; MIGENDA, N.; WELLER, J.; KOHLHASE, M.; SCHENCK, W.: Integrating Graph Retrieval-Augmented Generation into Prescriptive Analytics Platforms. MDPI - Big Data and Cognitive Computing, 2025

- [Nor11] NORTH, K.: Wissensorientierte Unternehmensführung – Wertschöpfung durch Wissen. 5. Auflage, Gabler Lehrbuch, Gabler Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden, Wiesbaden, 2011
- [NSM+20] NOLTE, V.; SINDRAM, T.; MAZAROV, J.; DEUSE, J.: Industrial Data Science erfolgreich implementieren. ZWF Zeitschrift für wirtschaftlichen Fabrikbetrieb, (115)10, 2020, S. 734–737
- [NVM13] NICKERSON, R. C.; VARSHNEY, U.; MUNTERMANN, J.: A method for taxonomy development and its application in information systems. European Journal of Information Systems, (22)3, 2013, S. 336–359
- [Ope24-ol] OPENGROUP: The ArchiMate® Enterprise Architecture Modeling Language – About the ArchiMate Modeling Language. Unter: <https://www.opengroup.org/archimate-forum/archimate-overview>, 28. Oktober 2025
- [Par23] PARTELOW, S.: What is a framework? Understanding their purpose, value, development and use. Journal of Environmental Studies and Sciences, (13)3, 2023, S. 510–519
- [Pat82] PATZAK, G.: Systemtechnik - Planung komplexer innovativer Systeme – Grundlagen, Methoden, Techniken. Springer, Berlin, 1982
- [PBK21] POKORNI, B.; BRAUN, M.; KNECHT, C.: Menschzentrierte KI-Anwendungen in der Produktion – Herausgegeben von Wilhelm Bauer, Oliver Riedel, Thomas Renner, Matthias Peissner. Fraunhofer-Institut für Arbeitswissenschaft und Organisation IAO, 2021
- [PCA14] PRAT, N.; COMYN-WATTIAU, I.; AKOKA, J.: ARTIFACT EVALUATION IN INFORMATION SYSTEMS DESIGN-SCIENCE RESEARCH – A HOLISTIC VIEW. Pacific Asia Conference on Information Systems (PACIS) Proceedings, 2014
- [PEM+22] PANZNER, M.; ENZBERG, S. VON; MEYER, M.; DUMITRESCU, R.: Characterization of Usage Data with the Help of Data Classifications. Journal of the Knowledge Economy, 2022
- [Per23-ol] PERRI, LORI: What’s New in Artificial Intelligence from the 2023 Gartner Hype Cycle. Unter: [https://www.gartner.com/en/articles/what-s-new-in-artificial-intelligence-from-the-2023-gartner-hype-cycle?utm\\_medium=email&\\_hsmi=275120785&\\_hsenc=p2ANqtz--VAH9FScy3i2FpLLJwN-ccBshPW4dGjQD-4cdzupT10XiHVO9mDv3IddolvgNkvtgwEBRa964jgE-fodXPMkky9GVGSKD7J4DE24gZn5aDRXz71ucw&utm\\_content=275062975&utm\\_source=hs\\_email](https://www.gartner.com/en/articles/what-s-new-in-artificial-intelligence-from-the-2023-gartner-hype-cycle?utm_medium=email&_hsmi=275120785&_hsenc=p2ANqtz--VAH9FScy3i2FpLLJwN-ccBshPW4dGjQD-4cdzupT10XiHVO9mDv3IddolvgNkvtgwEBRa964jgE-fodXPMkky9GVGSKD7J4DE24gZn5aDRXz71ucw&utm_content=275062975&utm_source=hs_email)
- [PF17] PROVOST, F.; FAWCETT, T.: Data Science für Unternehmen: Data Mining und datenanalytisches Denken praktisch anwenden. MITP Verlags GmbH & Co. KG; MITP, 2017

- [PF21] PEREA, R. V.; FESTIJO, E. D.: Analytics Platform for Morphometric Growth and Production Condition of Mud Crabs of the Genus *Scylla* with K-Means. 4th International Conference of Computer and Informatics Engineering (IC2IE), 2021, S. 117–122
- [Pfe17] PFEIFFER, S.: The Vision of "Industrie 4.0" in the Making-a Case of Future Told, Tamed, and Traded. *Nanoethics*, (11)1, 2017, S. 107–121
- [PFP09] PHAAL, R.; FARRUKH, C. J.; PROBERT, D. R.: Visualising strategy: a classification of graphical roadmap forms. *International Journal of Technology Management*, (47)4, 2009, S. 286
- [Pie11] PIEZUNKA, H.: Technological platforms. *Journal für Betriebswirtschaft*, (61)2-3, 2011, S. 179–226
- [Pie24] PIERRENKEMPER, C.: Systematik zur Entwicklung Leistungsstufen-basierter Industrie 4.0-Strategien – Dissertation. HNI Verlagsschriftenreihe, (Band 424), 2024
- [PLN+21] PADOVANO, A.; LONGO, F.; NICOLETTI, L.; GAZZANEO, L.; CHIURCO, A.; TALARICO, S.: A prescriptive maintenance system for intelligent production planning and control in a smart cyber-physical production line. *Procedia CIRP*, (104), 2021, S. 1819–1824
- [PME+22] PANZNER, M.; MEYER, M.; ENZBERG, S. VON; DUMITRESCU, R.: Business-to-Analytics Canvas - Translation of Product Planning-Related Business Use Cases into Concrete Data Analytics Tasks. *Procedia CIRP*, (109), 2022, S. 580–585
- [PMG98] POOLE, D. L.; MACKWORTH, A. K.; GOEBEL, R.: *Computational intelligence – A logical approach*. Oxford Univ. Press, New York, 1998
- [PP15] PÄÄKKÖNEN, P.; PAKKALA, D.: Reference Architecture and Classification of Technologies, Products and Services for Big Data Systems. *Big Data Research*, (2)4, 2015, S. 166–186
- [PP20] POORNIMA, S.; PUSHPALATHA, M.: A survey on various applications of prescriptive analytics. *International Journal of Intelligent Networks*, (1), 2020, S. 76–84
- [PPS+21] PARRI, J.; PATARA, F.; SAMPIETRO, S.; VICARIO, E.: A framework for Model-Driven Engineering of resilient software-controlled systems. *Computing*, (103)4, 2021, S. 589–612
- [PPW+21] PIORKOWSKI, D.; PARK, S.; WANG, A. Y.; WANG, D.; MULLER, M.; PORTNOY, F.: How AI Developers Overcome Communication Challenges in a Multidisciplinary Team. *Proceedings of the ACM on Human-Computer Interaction*, (5)CSCW1, 2021, S. 1–25

- [PTR+07] PEFFERS, K.; TUUNANEN, T.; ROTHENBERGER, M. A.; CHATTERJEE, S.: A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, (24)3, 2007, S. 45–77
- [Rab19] RABE, M.: Systematik zur Konzipierung von Smart Services für mechatronische Systeme – Dissertation. HNI Verlagsschriftenreihe, 2019
- [RBD+17] REINHART, G.; BENGLER, K.; DOLLINGER, C.; INTRA, C.; LOCK, C.; POPOVA-DLOGOSCH, S.; RIMPAU, C.; SCHMIDTLER, J.; TEUBNER, S.; VERNIM, S.: Der Mensch in der Produktion von Morgen. In: Reinhart, G. (Hrsg.): *Handbuch Industrie 4.0 – Geschäftsmodelle, Prozesse, Technik*. Hanser eLibrary, Carl Hanser Verlag, München, 2017
- [RBD24] RIBEIRO, V.; BARATA, J.; DA RUPINO CUNHA, P.: A Maturity Model for Data Governance in Decentralized Business Operations: Architecture and Assessment Archetypes. in Marcinkowski, A. Przybyłek, A. Jarzębowicz, N. Iivari, E. Insfran, M. Lang, H. Linger, & C. Schneider (Eds.), *Harnessing Opportunities: Reshaping ISD in the post-COVID-19 and Generative AI Era (ISD2024 Proceedings)*. Gdańsk, Poland: University of Gdańsk, 2024
- [Rei13] REINHARD, B.: *Business Capability Management – Gezielte Ausrichtung der Artefakte einer Unternehmensarchitektur*. eBook - Generate Value, 2013
- [Rei16] REINHART, F.: *Industrial Data Science - Data Science in der industriellen Anwendung*. *Industrie 4.0 Management*, 2016
- [Rei17] REINHART, G. (Hrsg.): *Handbuch Industrie 4.0 – Geschäftsmodelle, Prozesse, Technik*. Hanser eLibrary, Carl Hanser Verlag, München, 2017
- [RKD17] REINHART, F.; KÜHN, A.; DUMITRESCU, R.: Schichtenmodell für die Entwicklung von Data Science Anwendungen im Maschinen- und Anlagenbau. In: Bodden, E.; Dressler, F.; Dumitrescu, R.; Gausemeier, J.; Heide, F. M. auf der; Scheytt, C.; Trächtler, A. (Hrsg.): *Wissenschaftsforum Intelligente Technische Systeme (WInTeSys) 2017*, 2017
- [RKK+20] RANSBOTHAM, S.; KHODABANDEH, S.; KIRON, D.; CANDELON, F.; CHU, M.; LAFOUNTAIN, B.: *Expanding AI's Impact With Organizational Learning*. MITSloan Management Review Research report in collaboration with BCG, 2020
- [RLL16] RINGSQUANDL, M.; LAMPARTER, S.; LEPRATTI, R.: Graph-based predictions and recommendations in flexible manufacturing systems: IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society. *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, 23.10.2016 - 26.10.2016, Florence, Italy, IEEE, 2016, S. 6937–6942

- [RMB+21] RUEDEN, L. VON; MAYER, S.; BECKH, K.; GEORGIEV, B.; GIESSELBACH, S.; HEESE, R.; KIRSCH, B.; WALCZAK, M.; PFROMMER, J.; PICK, A.; RAMAMURTHY, R.; GARCKE, J.; BAUCKHAGE, C.; SCHUECKER, J.: Informed Machine Learning - A Taxonomy and Survey of Integrating Prior Knowledge into Learning Systems. *IEEE Transactions on Knowledge and Data Engineering*, 2021, S. 1
- [RNR22] REHMAN, A.; NAZ, S.; RAZZAK, I.: Leveraging big data analytics in healthcare enhancement: trends, challenges and opportunities. *Multimedia Systems*, (28)4, 2022, S. 1339–1371
- [Rol15] ROLLINGS, J.: *Foundational Methodology for Data Science*
- [Rot16] ROTH, A. (Hrsg.): *Einführung und Umsetzung von Industrie 4.0 – Grundlagen, Vorgehensmodell und Use Cases aus der Praxis*. Springer Gabler, Berlin, 2016
- [RPM+23] RIBEIRO, R.; PILASTRI, A.; MOURA, C.; MORGADO, J.; CORTEZ, P.: A data-driven intelligent decision support system that combines predictive and prescriptive analytics for the design of new textile fabrics. *Neural Computing and Applications*, (35)23, 2023, S. 17375–17395
- [RRH+24] REICHENSTEIN, T.; REICH, C. S.; HOFFMANN, K.; FRANKE, J.: From connectivity via intelligence toward sustainability? Maturity of shopfloor automation technology in the manufacturing industry. *Procedia CIRP*, (128), 2024, S. 436–441
- [RRK+22] RAFFIN, T.; REICHENSTEIN, T.; KLIER, D.; KÜHL, A.; FRANKE, J.: Qualitative assessment of the impact of manufacturing-specific influences on Machine Learning Operations. *Procedia CIRP*, (115), 2022, S. 136–141
- [RRW+22] RAFFIN, T.; REICHENSTEIN, T.; WERNER, J.; KÜHL, A.; FRANKE, J.: A reference architecture for the operationalization of machine learning models in manufacturing. *Procedia CIRP*, (115), 2022, S. 130–135
- [Rus09] RUSSELL, S.: *Artificial Intelligence: A Modern Approach*. 3. Auflage, Pearson., 2009
- [Saa78] SAATY, T. L.: Modeling unstructured decision problems — the theory of analytical hierarchies. *Mathematics and Computers in Simulation*, (20)3, 1978, S. 147–158
- [SAD+20] SCHUH, G.; ANDERL, R.; DUMITRESCU, R.; KRÜGER, A.; HOMPEL, M. TEN: *Industrie 4.0 Maturity Index. Die digitale Transformation von Unternehmen gestalten – UPDATE 2020 – (acatech STUDIE)*, 2020
- [SAH+22] SCHULZ, T.; AYAZ, B.K.; HUBER, M.; KRÖCKEL, J.; INGOLD, R.; OPPERMANN, H.; REIMANN, D.; TASCHEK, H. (Hrsg.): *Analytics in der Industrie – Schlüsseltechnologie für die digitale Transformation*. Vogel Communications Group, Würzburg, 2022

- [SBA+22] SAADALLAH, A.; BÜSCHER, J.; ABDULAATY, O.; PANUSCH, T.; DEUSE, J.; MORIK, K.: Explainable Predictive Quality Inspection using Deep Learning in Electronics Manufacturing. *Procedia CIRP*, (107), 2022, S. 594–599
- [Sch18] SCHNEIDER, M.: Spezifikationstechnik zur Beschreibung und Analyse von Wertschöpfungssystemen. Dissertation. HNI Verlagsschriftenreihe, (Band 386), 2018
- [SCP+21] SILVA, A. J.; CORTEZ, P.; PEREIRA, C.; PILASTRI, A.: Business analytics in Industry 4.0: A systematic review. *Expert Systems*, (38)7, 2021
- [SDD+17] SAGER, E. K.; DUPIER, G.; DECKNICK, A.; KOZEL, C.: A Framework to guide your data strategy. Booz Allen Hamilton Consulting, 2017
- [SGY+23] SIMEONE, A.; GRANT, R.; YE, W.; CAGGIANO, A.: A human-cyber-physical system for Operator 5.0 smart risk assessment. *The International Journal of Advanced Manufacturing Technology*, (129)5-6, 2023, S. 2763–2782
- [She00] SHEARER, C.: The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, (5)4, 2000, S. 13–22
- [SHP+11] SEIN, M. K.; HENFRIDSSON, O.; PURAO, S.; ROSSI, M.; LINDGREN, R.: Action Design Research. *MIS Quarterly*, (35)1, 2011, S. 37
- [Sie16] SIEPMANN, D.: Industrie 4.0 - Grundlagen und Gesamtzusammenhang. In: Roth, A. (Hrsg.): Einführung und Umsetzung von Industrie 4.0 – Grundlagen, Vorgehensmodell und Use Cases aus der Praxis. Springer Gabler, Berlin, 2016
- [Sie23] SIEMENS AG: Senseye Predictive Maintenance - Whitepaper True Cost Of Downtime 2022, 2023
- [Šik14] ŠIKŠNYS, L.: Towards Prescriptive Analytics in Cyber-Physical Systems – Ph.D. Thesis, 2014
- [Sim60] SIMON, H. A.: The new science of management decision. Harper & Brothers, New York, 1960
- [Sim96] SIMON, H. A.: The sciences of the artificial. 3rd Edition, MIT Press, Cambridge, Mass., 1996
- [SKK+23] SCHREINER, N.; KÜRPICK, C.; KÜHN, A.; DUMITRESCU, R.: Sustainability Data Map: Framework for Data-Based Product Carbon Footprinting of Technical Products. Global Conference on sustainable manufacturing 2023, Buenos Aires, 2023
- [SKY+23] SAM PLAMOOTTIL, S.; KUNDEN, B.; YADAV, A.; MOHANTY, T.: Inventory Waste Management with Augmented Analytics for Finished Goods. Third International Conference on Artificial Intelligence and Smart Energy (ICAIS), 2023, S. 1293–1299

- [SMF18] STEIN, N.; MELLER, J.; FLATH, C. M.: Big data on the shop-floor: sensor-based decision-support for manual processes. *Journal of Business Economics*, (88)5, 2018, S. 593–616
- [SOL+22] SHTEINGART, H.; OOSTRA, G.; LEVINKRON, O.; PARUSH, N.; SHABAT, G.; ARONOVICH, D.: *Machine Learning Prescriptive Canvas for Optimizing Business Outcomes*, 2022
- [SPB+19] SCHUH, G.; PROTE, J.-P.; BUSAM, T.; LORENZ, R.; NETLAND, T. H.: *Using Prescriptive Analytics to Support the Continuous Improvement Process*, 2019
- [SS14] SCHUH, G.; SCHMIDT, C.: *Produktionsmanagement – Handbuch Produktionsmanagement (5) - 2., vollständig neu bearbeitete und erweiterte Auflage*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2014
- [SS16] SOLTANPOOR, R.; SELLIS, T.: Prescriptive Analytics for Big Data. *Database Theory and Applications, 27th Australasian Database Conference, ADC 2016*, (9877), 2016, S. 245–256
- [SS21] SCHULER, K.; SCHLEGEL, D.: A Framework for Corporate Artificial Intelligence Strategy. Jallouli, R., Bach Tobji, M.A., Mcheick, H., Piho, G. (eds) *Digital Economy. Emerging Technologies and Business Innovation. (ICDEc) - Lecture Notes in Business Information Processing*, (431)vol 431., 2021, S. 121–133
- [SSK+14-ol] SALLAM, R.; STEENTRUP, K.; LEIF, E.; JACOBSON, S.: *Industrial Analytics Revolutionizes Big Data in the Digital Business*, 2014
- [SSS+20] SCHULTE, L.; SCHMITT, J.; STANKIEWICZ, L.; DEUSE, J.: *Industrial Data Science - Interdisciplinary Competence for Machine Learning in Industrial Production*. In: Schüppstuhl, T.; Tracht, K.; Henrich, D. (Eds.): *Annals of scientific society for assembly, handling and industrial robotics*. Springer Open, Springer Vieweg, Berlin, 2020, pp. 161–171
- [SST+23] SCHUETZ, C. G.; SELWAY, M.; THALMANN, S.; SCHREFL, M.: *Discovering Actionable Knowledge for Industry 4.0 From Data Mining to Predictive and Prescriptive Analytics*. In: Vogel-Heuser, B.; Wimmer, M. (Hrsg.): *Digital Transformation – Core technologies and emerging topics from a computer science perspective*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2023, S. 337
- [SSW23] SUSANTO, A. H.; SIMATUPANG, T.; WASESA, M.: *Industry 4.0 Maturity Models to Support Smart Manufacturing Transformation: A Systematic Literature Review*. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informatika)*, (7)2, 2023, S. 334–344
- [Stu18] STUHT, T.: *Vereinigung von detaillierten Teilmodellen in einer flexiblen Enterprise Architecture zur übergreifenden Analyse – Dissertation*. Technische Fakultät der Christian-Albrechts-Universität Kiel, 2018

- [SVA+22] SILVA, S.; VYAS, V.; AFONSO, P.; BORIS, B.: Prescriptive Cost Analysis in Manufacturing Systems. *IFAC-PapersOnLine*, (55)10, 2022, S. 484–489
- [SvS+24] SAGODI, A.; VAN GIFFEN, B.; SCHNIERTSHAUER, J.; NIEHUES, K.; VOM BROCKE, J.: How Audi Scales Artificial Intelligence in Manufacturing – Realizing Business Value from Artificial Intelligence Scaling Is Challenging. *MIS Quarterly Executive*, 2024
- [SWK+24] SYBERG, M.; WEST, N.; KLAPIC, E.; SCHWENKEN, J.; KLINKENBERG, R.; DEUSE, J.: Abstraktion und Übertragbarkeit von Datenanalysen im industriellen Kontext – Entwicklung von modularisierten Analysebausteinen zur Nutzung in industriellen Anwendungsfällen. In: Deuse, J.; Klinkenberg, R.; West, N. (Hrsg.): *Industrielle Datenanalyse – Entwicklung einer Datenanalyse-Plattform für die wertschaffende, kompetenzorientierte Kollaboration in dynamischen Wertschöpfungsnetzwerken*. Springer Vieweg, Wiesbaden, 2024
- [SXX+20] SHI, Z.; XIE, Y.; XUE, W.; CHEN, Y.; FU, L.; XU, X.: Smart factory in Industry 4.0. *Systems Research and Behavioral Science*, (37)4, 2020, S. 607–617
- [SZ18] STEFANI, K.; ZSCHECH, P.: Constituent Elements for Prescriptive Analytics Systems. *Twenty-Sixth European Conference on Information Systems (ECIS 2018)*At: Portsmouth, UK, 2018
- [TBH20] TRUNK, A.; BIRKEL, H.; HARTMANN, E.: On the current state of combining human and artificial intelligence for strategic organizational decision making. *Business Research*, (13)3, 2020, S. 875–919
- [TDB+15] TSCHIRNER, C.; DUMITRESCU, R.; BANSMANN, M.; GAUSEMEIER, J.: Tailoring Model-Based Systems Engineering concepts for industrial application: 2015 Annual IEEE Systems Conference (SysCon) Proceedings. 2015 9th Annual IEEE International Systems Conference (SysCon), 13.04.2015 - 16.04.2015, Vancouver, BC, Canada, IEEE, 2015, S. 69–76
- [Tho19] THOMAS, J.: AI Ops – Managing the End-to-End Lifecycle of AI
- [Tho23] THOMAS, D.: Revolutionizing Failure Modes and Effects Analysis with ChatGPT: Unleashing the Power of AI Language Models. *Journal of Failure Analysis and Prevention*, (23)3, 2023, S. 911–913
- [Togaf10] THE OPEN GROUP: *The TOGAF® Standard, 10th Edition - Introduction and Core Concepts*. Van Haren Publishing, Hertogenbosch, 2022
- [TSH23] THAM, C.-K.; SHARMA, N.; HU, J.: Model-based and Model-free Prescriptive Maintenance on Edge Computing Nodes: 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring). 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring), 20.06.2023 - 23.06.2023, Florence, Italy, IEEE, 2023, S. 1–6

- [TTX+04] TINGDI, Z.; TIEJUN, S.; XIAO, H.; LINLING, S.: Intelligent FMEA based on model FIORN: Annual Symposium Reliability and Maintainability, 2004 - RAMS. Annual Symposium Reliability and Maintainability, 2004 - RAMS, Jan. 26-29, 2004, Los Angeles, CA, USA, IEEE, 2004, S. 386–390
- [TW18] THAMMABOOSADEE, S.; WONGPITAK, P.: An Integration of Requirement Forecasting and Customer Segmentation Models towards Prescriptive Analytics For Electrical Devices Production: 2018 International Conference on Information Technology (InCIT). 2018 International Conference on Information Technology (InCIT), 24.10.2018 - 26.10.2018, Khon Kaen, IEEE, 2018, S. 1–5
- [TWK+24] TISSEN, D.; WIEDERKEHR, I.; KOLDEWEY, C.; DUMITRESCU, R.: Data from start to finish: A System Life Cycle Data Map. *Procedia CIRP*, (122), 2024, S. 413–418
- [Uli13] ULICH, E.: Arbeitssysteme als Soziotechnische Systeme – eine Erinnerung – Institut für Arbeitsforschung und Organisationsberatung, Zürich. *Journal Psychologie des Alltagshandelns*, 2013
- [VBH15] VANAUER, M.; BOHLE, C.; HELLINGRATH, B.: Guiding the Introduction of Big Data in Organizations: A Methodology with Business- and Data-Driven Ideation and Enterprise Architecture Management-Based Implementation. IEEE, 2015
- [VDI/VDE 3714] VDI-Richtlinie - Implementierung von Big-Data-Anwendungen in der produzierenden Industrie – Blatt 4 - Analyseverfahrensklassen, 2022
- [VDI/VDE 3714 Blatt 1] VDI-Richtlinie - Implementierung von Big-Data-Anwendungen in der produzierenden Industrie – Blatt 1 - Durchführung von Big-Data-Projekten, 2022
- [VHK19a] VATER, J.; HARSCHIEDT, L.; KNOLL, A.: A Reference Architecture Based on Edge and Cloud Computing for Smart Manufacturing. *Proceedings - International Conference on Computer Communications and Networks, ICCCN*, 2019, S. 1–7
- [VHK19b] VATER, J.; HARSCHIEDT, L.; KNOLL, A.: Smart Manufacturing with Prescriptive Analytics – ICITM 2019 March 2-4, 2019, Cambridge, UK. IEEE, Piscataway, NJ, 2019
- [vP23] VAN RIEL, J.; POELS, G.: A Method for Developing Generic Capability Maps. *Business & Information Systems Engineering*, (65)4, 2023, S. 403–424
- [VP23] VINAYAVEKHIN, S.; PHAAL, R.: Roadmapping for Strategic Alignment, Integration and Synchronization. In: Daim, T. U.; Phaal, R.; Meissner,

- D.; Kerr, C. (Eds.): Next Generation Roadmapping – Establishing Technology and Innovation Pathways Towards Sustainable Value. Science, Technology and Innovation Studies, Springer International Publishing; Imprint Springer, Cham, 2023, pp. 1–24
- [VPB12] VENABLE, J.; PRIES-HEJE, J.; BASKERVILLE, R.: A Comprehensive Framework for Evaluation in Design Science Research. In: Hutchison, D.; Kanade, T.; Kittler, J.; Kleinberg, J. M.; Mattern, F.; Mitchell, J. C.; Naor, M.; Nierstrasz, O.; Pandu Rangan, C.; Steffen, B.; Sudan, M.; Terzopoulos, D.; Tygar, D.; Vardi, M. Y.; Weikum, G.; Peffers, K.; Rothemberger, M.; Kuechler, B. (Hrsg.): Design Science Research in Information Systems. Advances in Theory and Practice. Lecture Notes in Computer Science, Springer Berlin Heidelberg, Berlin, Heidelberg, 2012, S. 423–438
- [VSK+19] VATER, J.; SCHAMBERGER, P.; KNOLL, A.; WINKLE, D.: Fault classification and correction based on convolutional neural networks exemplified by laser welding of hairpin windings. In: EDPC (Hrsg.): 9th International Electric Drives Production Conference, 2019 - Proceedings, 2019
- [VSK20] VATER, J.; SCHLAAK, P.; KNOLL, A.: A Modular Edge-/Cloud-Solution for Automated Error Detection of Industrial Hairpin Weldings using Convolutional Neural Networks. 2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC), Madrid, Spain, 2020, S. 505–510
- [VvP23] VANDEVENNE, N.; VAN RIEL, J.; POELS, G.: Green Enterprise Architecture (GREAN)—Leveraging EA for Environmentally Sustainable Digital Transformation. Sustainability, (15)19, 2023, S. 14342
- [WB23] WORLD ECONOMIC FORUM; BOSTON CONSULTING GROUP: Using AI in Industrial Operations Guidebook, 2023
- [WD25] WELLER, J.; DUMITRESCU, R.: Decision Driven Analytics in Smart Factories: Enterprise Architecture Framework for Use Case Specification and Engineering (FUSE). MDPI Electronics - Special Issue - Applications of Artificial Intelligence in Intelligent Manufacturing (under review), 2025
- [WDB13] WÖHE, G.; DÖRING, U.; BRÖSEL, G.: Einführung in die allgemeine Betriebswirtschaftslehre. Vahlens Handbücher der Wirtschafts- und Sozialwissenschaften, Verlag Franz Vahlen, München, 2013
- [Wes17] WESTERMANN, T.: Systematik zur Reifegradmodell-basierten Planung von Cyber-Physical Systems des Maschinen- und Anlagenbaus. HNI Verlagsschriftenreihe, 2017
- [WGB+21] WEST, N.; GRIES, J.; BROCKMEIER, C.; GOBEL, J. C.; DEUSE, J.: Towards integrated Data Analysis Quality: Criteria for the application of Industrial Data Science: 2021 IEEE 22nd International Conference on Information

- Reuse and Integration for Data Science (IRI). 2021 IEEE 22nd International Conference on Information Reuse and Integration for Data Science (IRI), 10.08.2021 - 12.08.2021, Las Vegas, NV, USA, IEEE, 2021, S. 131–138
- [WH22] WESENDRUP, K.; HELLINGRATH, B.: A Prescriptive Maintenance Aligned Production Planning and Control Reference Process, 2022
- [WHD24] WEST, N.; HUBER, T.; DEUSE, J.: Industrielle Datenanalysen im Mittelstand – Hintergrund der Forschungsförderung und Nutzen der Forschungsergebnisse für mittelständische Unternehmen. In: Deuse, J.; Klinkenberg, R.; West, N. (Hrsg.): Industrielle Datenanalyse – Entwicklung einer Datenanalyse-Plattform für die wertschaffende, kompetenzorientierte Kollaboration in dynamischen Wertschöpfungsnetzwerken. Springer Vieweg, Wiesbaden, 2024
- [Wil13] WILSON, C.: Brainstorming. Brainstorming and Beyond, 2013, S. 1–41
- [Win93] WINSTON, P. H.: Artificial intelligence. 3rd Edition, Addison-Wesley, Reading, Mass., 1993
- [Wiß18] WIBOTZKI, M.: Capability Management Guide. Springer Fachmedien Wiesbaden, Wiesbaden, 2018
- [WLB+25] WELLER, J.; LICK, J.; BROCK, J.; HEUWINKEL, T.; HARTMANN, S.; KÜHN, A.; ENZBERG, S. VON; DUMITRESCU, R.: Advanced Analytics Capability Map for Smart Factories: Supporting the Planning, Design, Management and Operations of Advanced Analytics Use Cases. Procedia CIRP, (134), 2025, S. 223–228
- [WME+24] WELLER, J.; MIGENDA, N.; ENZBERG, S. VON; KOHLHASE, M.; SCHENCK, W.; DUMITRESCU, R.: Design decisions for integrating Prescriptive Analytics Use Cases into Smart Factories. Procedia CIRP, (128), 2024, S. 424–429
- [WMH+18] WIBBING, P.; MATYSCZOK, C.; HOHLWEGER, N.; ILCIN, M.: Die Auswirkung von Industrie 4.0 auf die Digitale Fabrik. ProduktDaten Journal, 2018
- [WMK+24] WELLER, J.; MIGENDA, N.; KÜHN, A.; DUMITRESCU, R.: Prescriptive Analytics Data Canvas: Strategic Planning For Prescriptive Analytics In Smart Factories. CPSL - Conference on Production Systems and Logistics 2024 (Hawaii, Honolulu), Hannover publish-Ing, 2024
- [WML+23] WELLER, J.; MIGENDA, N.; LIU, R.; WEGEL, A.; ENZBERG, S. VON; KOHLHASE, M.; SCHENCK, W.; DUMITRESCU, R.: Towards a Systematic Approach for Prescriptive Analytics Use Cases in Smart Factories. Band 18, ML4CPS - Machine Learning for cyber physical systems, 2023
- [WMN+24] WELLER, J.; MIGENDA, N.; NAIK, Y.; HEUWINKEL, T.; KÜHN, A.; KOHLHASE, M.; SCHENCK, W.; DUMITRESCU, R.: Reference Architecture for the

- Integration of Prescriptive Analytics Use Cases in Smart Factories. *Mathematics (MDPI) - Special Issue for Selected Papers From the 2023 IEEE International Conference on Advances in Data-Driven Analytics and Intelligent Systems*, 2024, (12)17, 2024, S. 2663
- [WMW+23] WELLER, J.; MIGENDA, N.; WEGEL, A.; KOHLHASE, M.; SCHENCK, W.; DUMITRESCU, R.: Conceptual Framework for Prescriptive Analytics Based on Decision Theory in Smart Factories. *IEEE ADACIS - ADACIS 2023 International Conference on Advances in Data-driven Analytics and Intelligent Systems*, 2023, S. 1–7
- [WNG+25] WELLER, J.; NALAVADE, S.; GMELCH, O.; MIGENDA, N.; HEUWINKEL, T.; DUMITRESCU, R.: Advanced Analytics in Smart Factories: Towards an actionable Taxonomy for Prescriptive Analytics Use Cases. *Procedia CIRP*, (134), 2025, S. 229–234
- [WRE+23] WELLER, J.; ROESMANN, D.; EGGERT, S.; ENZBERG, S. VON; GRÄBLER, I.; DUMITRESCU, R.: Identification and prediction of standard times in machining for precision steel tubes through the usage of data analytics. *33rd CIRP Design Conference*, 2023
- [WSS+18] WOO, J.; SHIN, S.-J.; SEO, W.; MEILANITASARI, P.: Developing a big data analytics platform for manufacturing systems: architecture, method, and implementation. *The International Journal of Advanced Manufacturing Technology*, (99)9-12, 2018, S. 2193–2217
- [WST+20] WOSTMANN, R.; SCHLUNDER, P.; TEMME, F.; KLINKENBERG, R.; KIMBERGER, J.; SPICHTINGER, A.; GOLDHACKER, M.; DEUSE, J.: Conception of a Reference Architecture for Machine Learning in the Process Industry: 2020 IEEE International Conference on Big Data (Big Data). *2020 IEEE International Conference on Big Data (Big Data)*, 10.12.2020 - 13.12.2020, Atlanta, GA, USA, IEEE, 2020, S. 1726–1735
- [WWS+24] WINDMANN, A.; WITTENBERG, P.; SCHIESECK, M.; NIGGEMANN, O.: Artificial Intelligence in Industry 4.0: A Review of Integration Challenges for Industrial Systems, 2024
- [WZ23] WISSUCHEK, C.; ZSCHECH, P.: Survey and Systematization of Prescriptive Analytics Systems: Towards Archetypes from a Human-Machine-Collaboration Perspective. *ECIS*, 2023
- [WZ24] WISSUCHEK, C.; ZSCHECH, P.: Prescriptive analytics systems revised: a systematic literature review from an information systems perspective. *Information Systems and e-Business Management*, 2024
- [YK15] YIN, S.; KAYNAK, O.: Big Data for Modern Industry: Challenges and Trends [Point of View]. *Proceedings of the IEEE*, (103)2, 2015, S. 143–146

- [Zac87] ZACHMAN, J. A.: A framework for information systems architecture – The Zachman Framework, Enterprise Architecture. IBM Systems Journal Reprint, 1987
- [ZLL+18] ZHANG, B.; LI, W.; LI, X.-L.; NG, S.-K.: Intelligent Fault Diagnosis Under Varying Working Conditions Based on Domain Adaptive Convolutional Neural Networks. IEEE Access, (6), 2018, S. 66367–66384
- [ZM23] ZHANG, X.; MING, X.: A Smart system in Manufacturing with Mass Personalization (S-MMP) for blueprint and scenario driven by industrial model transformation. Journal of Intelligent Manufacturing, (34)4, 2023, S. 1875–1893
- [Zsc23] ZSCHECH, P.: Beyond descriptive taxonomies in data analytics: a systematic evaluation approach for data-driven method pipelines. Information Systems and e-Business Management, (21)1, 2023, S. 193–227
- [ZWD+21] ZENKERT, J.; WEBER, C.; DORNHÖFER, M.; ABU-RASHEED, H.; FATHI, M.: Knowledge Integration in Smart Factories. Encyclopedia, (1)3, 2021, S. 792–811

## Anhang

<b>A1</b>	<b>Ergänzungen zur Problemanalyse .....</b>	<b>A-3</b>
A1.1	Künstliche Intelligenz für Industrial Data Science .....	A-3
A1.2	Aktionen und Entscheidungen .....	A-4
A1.3	Schnittmengen und angrenzende relevante Konzepte .....	A-5
A1.4	Daten für Industrial Data Science .....	A-8
A1.5	Sammlung von Prescriptive Analytics Use Cases .....	A-10
<b>A2</b>	<b>Ergänzungen zur Spezifikationstechnik .....</b>	<b>11</b>
A2.1	Rahmenwerk für Industrial Data Science .....	A-11
A2.2	Design Prinzipien für Prescriptive Analytics Use Cases .....	A-12
A2.3	Subkategorien der Taxonomie für Prescriptive Analytics Use Cases .....	A-13
A2.4	Meta-Recommender Ansatz für Prescriptive Analytics Use Cases .....	A-16
A2.5	Mapping von Concerns und Partialmodellen .....	A-17
A2.6	Ergänzende Informationen zum Metamodell .....	A-19
A2.7	Vergleich der Spezialisierung mit etablierten Metamodellen .....	A-23
A2.8	Blueprints und One Pager für das Partialmodellkonzept .....	A-28
A2.9	Use Case Transformation Canvas mit Leitfragen .....	A-35
A2.10	Detaillierte Prescriptive Analytics Capability Map .....	A-36
A2.11	Beispielhafte Analysefragen für das Modell .....	A-48
<b>A3</b>	<b>Forschungsdesign der Spezifikationstechnik .....</b>	<b>A-49</b>
A3.1	Herleitung des übergeordneten Vorgehensmodells .....	A-49
A3.2	Herleitung des Modellierungskonzepts .....	A-55
A3.3	Forschungsvorgehen der Artefakte .....	A-56
<b>A4</b>	<b>Ergänzungen zur Demonstration und Evaluation der Spezifikationstechnik .....</b>	<b>A-67</b>
A4.1	Ausgefüllte Use Case Transformation Canvas .....	A-67
A4.2	Initial bewertete Capability Map .....	A-68
A4.3	Detailliertes Use Case Portfolio .....	A-69
A4.4	Detaillierte Data Map .....	A-71
A4.5	Detaillierte Analytics Canvas .....	A-72
A4.6	Detaillierte Applikationsarchitektur .....	A-73
A4.7	Datenkatalog der IoT Factory .....	A-74

A4.8 Datenobjektbasierte Roadmap .....	A-75
A4.9 Detaillierte Pipeline .....	A-77
A4.10 Ergebnisse der Nutzerevaluation.....	A-80

## A1 Ergänzungen zur Problemanalyse

Im Folgenden werden Ergänzungen zur Problemanalyse beschrieben. Diese Ergänzungen dienen lediglich der weiteren Ausführung teilweise angeschnittener Aspekte.

### A1.1 Künstliche Intelligenz für Industrial Data Science

Generell herrscht **kein Konsens für eine einheitliche Definition** von KI vor [Rus09, S. 1024]. Vor dem Nennen einer Definition gilt es, die verschiedenen Perspektiven bei der Eingrenzung zu verstehen. Definitionen fokussieren sich auf die Logik der Ergebniserzeugung (mensenähnlich [Hau85] oder rational [Win93]) oder die Art des nachgeahmten Verhaltens (mensenähnlich [Kur90] oder rational [PMG98]) [Rus09, S. 2]. Die Definition von KI und KI-Systemen sind nach der DIN EN ISO/IEC 22989 eng verschachtelt. **KI** behandelt die „*Forschung und Entwicklung von Mechanismen und Anwendungen von KI-Systemen*“. Darauf aufbauend ist ein **KI-System** definiert als ein „*technisches System, das Ergebnisse wie Inhalte, Prognosen, Empfehlungen oder Entscheidungen für eine bestimmte, von Menschen definierte Zielsetzung erzeugt*“ [DIN22989, S. 8]. Data Science bedient im Bereich der KI verschiedener Techniken (vgl. Bild A-1) [KKM+20, S. 5].

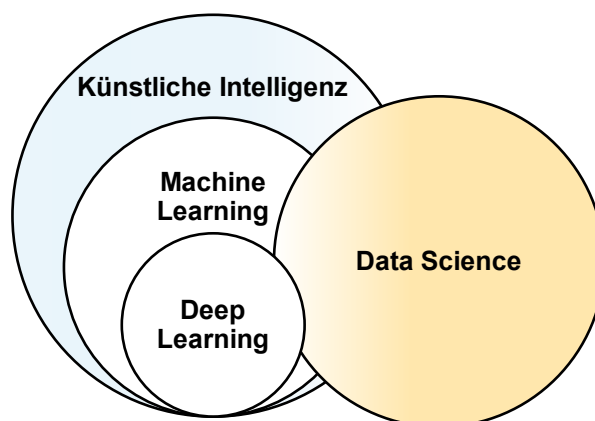


Bild A-1: Zusammenhang der Begrifflichkeiten rund um Künstliche Intelligenz und Data Science in Anlehnung an [KKM+20, S. 5]

Für die Data Science spielt **Künstliche Intelligenz** eine besondere Rolle [Cao18]. **Machine Learning** (Deutsch.: *maschinelles Lernen*) ist eine Teilmenge des übergeordneten Feldes der Künstlichen Intelligenz [CLR+19, S. 83]. Machine Learning umschreibt eine definierte Menge an Techniken, welche mithilfe von lernenden Eigenschaften (steigende Performance bei mehr Erfahrung) Aufgaben abbilden können [KKM+20, S. 5, MBD+90]. Als Teilmenge des Machine Learnings gilt das sogenannte **Deep Learning** (Deutsch.: *tiefes Lernen*). Deep Learning ermöglicht Modellen die Verarbeitung von Daten auf mehreren Abstraktionsebenen durch die Nutzung von verschachtelten Modellen und Modellarchitekturen [LBH15].

## A1.2 Aktionen und Entscheidungen

Im Folgenden werden, die für **Prescriptive Analytics** zugrundeliegenden Begriffe, Entscheidung und Aktion definiert. Dabei definiert sich eine **Entscheidung** wie folgt:

*„Eine Entscheidung ist ein Akt, bei dem eine von mehreren möglichen Handlungsalternativen ausgewählt wird, um ein bestimmtes Ziel zu erreichen.“ [Moc21, S. 162]*

In einem Entscheidungsprozess werden Handlungsalternativen in **Aktionen** umgewandelt [BUB16, S. 8]. Dabei sind Entscheidungen als Prozess zu betrachten, welcher einen Auslöser benötigt (die sogenannte Notwendigkeit der Entscheidung) [BUB16, S. 8]. Handlungen basierend auf einer Entscheidungsgrundlage [Nor11, S. 36]. Diese wird aus der Transformation von Zeichen bis hin zu **Informationen** und **Wissen** abgeleitet [BUB16, S. 14].

Die Kombination von Zeichen mit einer spezifischen Syntax erzeugt **Daten**. Daten angereichert mit ihrer spezifischen Bedeutung werden als **Informationen** beschrieben. Mithilfe von Maßnahmen des operativen Informationsmanagements wird durch die Anreicherung von Informationen mit Kontext, Erfahrungen und Erwartungen (generell: Vernetzung) Wissen erzeugt. **Wissen** stellt die zweckdienliche Vernetzung von Informationen dar [Nor11, S. 37]. Expertenwissen beschreibt die lokale Verfügbarkeit von Wissen, welches einer bestimmten Personengruppe zugeordnet wird [RMB+21, S. 5]. Nach *DIN EN ISO/IEC 22989* besitzt Wissen im Kontext von Künstlicher Intelligenz primär die Eigenschaft, dass es organisiert ist und dadurch für den systematischen Gebrauch zur Verfügung steht [DIN22989, S. 11].

Wie Entscheidungen jedoch in der betrieblichen Praxis gefällt werden und welche Prozesse dahinter liegen, spielt im Unternehmenskontext eine wichtige Rolle [BUB16, S. 12]. Menschliche Entscheidungen basieren oftmals nicht auf strukturierten rationalen Prozessen, sondern auf primär intuitiven Abläufen [Jar18, S. 579]. Aus diesem Grund implizieren verschiedene Autoren den wichtigen Bestandteil menschlicher Einflüsse in der finalen Entscheidung [KGK23, S. 180]. Im Unternehmenskontext wird dieser idealtypische Ablauf von einer Reihe von Grundprinzipien beeinflusst:

A1) **Bounded Rationality** (deutsch: *begrenzte Rationalität*) und **Optimalität**: Es gibt mathematische Optimalität und Optimalität, die den Umständen gerecht wird. In Entscheidungsprozessen wird oft mit letzterem vorliebig genommen [LYH+19, S. 286]. Dies stellt den pragmatischeren Ansatz dar, da Entscheidungen in Unternehmen oft rasch und unter unvollständiger Informationslage getroffen werden [Hül21, Sim60]. Entscheidungen werden in diesem Kontext unter Unsicherheit getroffen und ein Grad an Rationalität an den Tag gelegt, der den Gegebenheiten entspricht. Es wird ohne perfekte Informationslage entschieden [TBH20, S. 876, Sim60].

A2) **Counterfactual Reasoning** (deutsch: *kontrafaktisches Denken*). Der Begriff beschreibt die menschliche Fähigkeit, aus dem Nichteintreten eines Ereignisses die Folgen bei einem Eintreten abzuschätzen. Eine Abbildung dieser menschlichen Eigenschaften in algorithmischen Ansätzen steht bisher aus. [SOL+22]

### A1.3 Schnittmengen und angrenzende relevante Konzepte

Die Perspektiven der **Psychologie** und **Philosophie**, der **Wirtschaftsinformatik**, **Regelungstechnik**, der **Management-Wissenschaft**, **Statistik** und **Stochastik** sowie der **Data Science** und **KI** stellen eigene Wortschöpfungen zur Umschreibung des Themenfeldes der Prescriptive Analytics bereit. In Bild A-2 wird ein Überblick über verwandte Begriffsfelder, die Sichten und die für die Ausarbeitung relevante Bezugsdomäne gegeben. Hierbei dienen die Schnittmengen lediglich als qualitativer Überblick (vgl. Bild A-2).

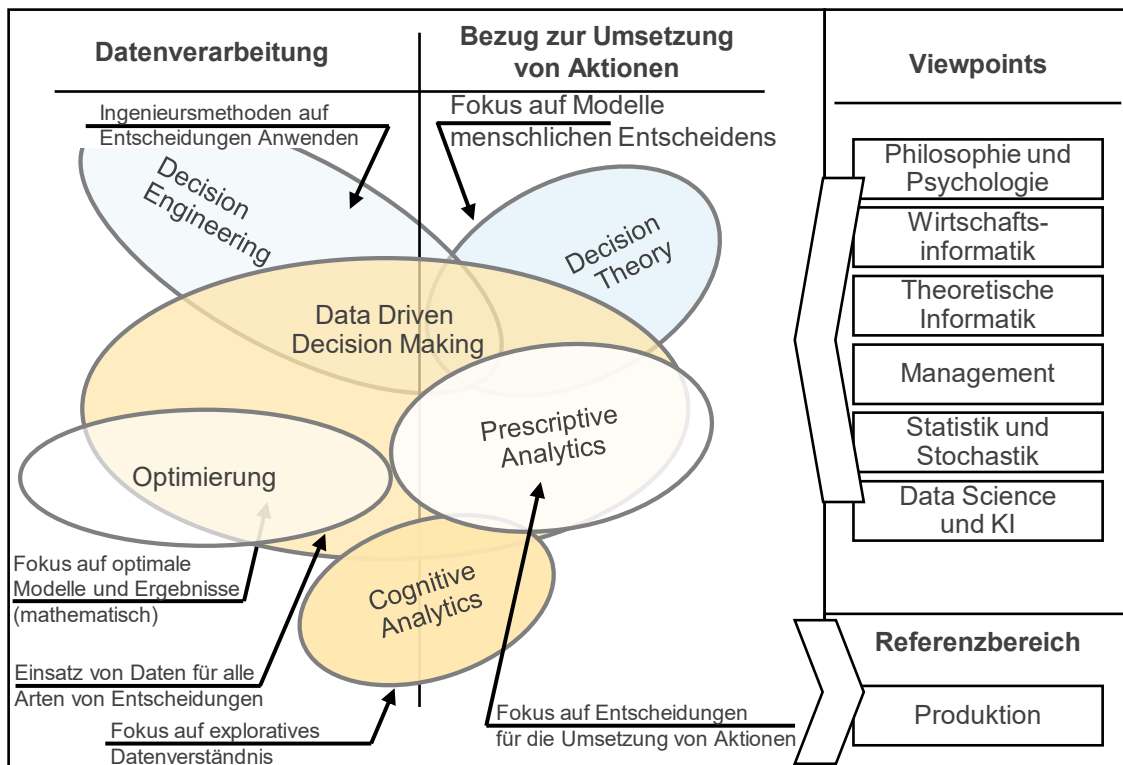


Bild A-2: Überblick über die Schnittmengen in den Begriffen rund um das Thema Prescriptive Analytics und Data Driven Decision Making

Alle im Bild aufgeführten Begriffe werden in der folgenden Tabelle A-1 definiert. Dabei sind die Definitionen teilweise aus dem Englischen übersetzt. Darauf basierend wird der Begriff des (Data Driven) Decision Makings weiter analysiert.

Tabelle A-1: Abgrenzung zu relevanten Begriffen in der Ausarbeitung

Decision Engineering	„Die Entscheidungsanalyse ist ein technischer Ansatz, der Entscheidungsträgern hilft, rationale Entscheidungen zu treffen. [...] Bei der Entscheidungsanalyse werden Instrumente wie Entscheidungstheorie, Einflussdiagramme, Systemdynamik, Spieltheorie usw. eingesetzt, um gute Entscheidungen bei der Entwicklung neuer Produkte, der Unternehmensstrategie und der Sicherheit von Systemen zu entwickeln.“ (aus dem Englischen Übersetzt) [Mat05, S. 195]
Decision Theory	„Die Entscheidungstheorie versucht uns zu erklären, wie die Überzeugungen und Wünsche eines Akteurs zusammen bestimmen, was er tun sollte. Sie kombiniert ihre Nutzenfunktion und ihre Wahrscheinlichkeitsfunktion, um einen Wert für jede mögliche Handlung zu ermitteln, der als Erwartung oder Erwünschtheit dieser Handlung bezeichnet wird (ähnlich wie die Formel für die Erwartung einer Zufallsvariablen).“ (aus dem Englischen Übersetzt) [Háj11]
Optimierung	„Die Optimierung ist die Disziplin der Suche nach der besten Alternative aus einer Menge unter Berücksichtigung eines bestimmten Kriteriums und gegebener Beschränkungen. [...] Das Ziel dieser Methoden ist es, die Alternative zu finden, die entweder den Aufwand minimiert oder den gewünschten Nutzen maximiert, der mit dem betrachteten Problem verbunden ist.“ (aus dem Englischen Übersetzt) [CLR+19, S. 1299]
Cognitive Analytics	„Automatisierte Vorhersagen, Empfehlungen und Erkennungen für intelligentere Entscheidungen im Laufe der Zeit unter Berücksichtigung adaptiver und lernender Prozesse.“ (aus dem Englischen Übersetzt) [MKL+19, S. 568]
Prescriptive Analytics	Siehe Kapitel 2.1.3
Data Driven Decision Making	Siehe Anhang A1.3


## Entscheidungsfindung (Englisch: Decision-Making Process)

Die **Entscheidungstheorie** unterscheidet zwischen deskriptiven, normativen und präskriptiven Ansätzen [SZ18]. Dabei liegt der Fokus präskriptiver Ansätze auf der Erklärbarkeit und Unterstützung realer Entscheidungsabläufe [Kee92]<sup>20</sup>. Die präskriptive Entscheidungstheorie wurde insbesondere von Ingenieuren als Werkzeug zur Analyse von Unternehmensprozessen verwendet [AB95]. Weiterhin differenziert die Entscheidungstheorie zwischen strukturierten und unstrukturierten Entscheidungen. Unstrukturierte Entscheidungen werden durch ihre Ungewissheit oder Komplexität in Frage- und Antwortsystem definiert [Saa78]. Ein ähnlicher Unterscheidungsansatz ist der der programmierbaren und nicht programmierbaren Entscheidungen. Strukturierte Entscheidungen können über Modelle oder Algorithmen abgebildet werden. Nicht programmierbare Entscheidungen sind entweder zu komplex oder zu rechenintensiv für eine Abbildung in einem Entscheidungsmodell [LYH+19, S. 287].

<sup>20</sup>Das Wort Präskription umschreibt im Allgemeinen den empfehlenden Charakter des anliegenden Satzteils. Die präskriptive Entscheidungstheorie hat somit nur bedingt etwas mit dem Begriff Prescriptive Analytics zu tun.

**Schwachstellen** in der Anwendung klassischer Entscheidungstheorie auf aktuelle Probleme und Problemlösung durch KI-Ansätze liegen in der Missachtung von **Komplexität** und **Rechenaufwänden** bei der Unterstützung durch Algorithmen. Diese beiden Faktoren sind hauptverantwortlich für das Fehlen „echter“ Rationalität in Entscheidungsunterstützungssystemen [Hül21].

Entscheidungsprozesse folgen immer gleichen Strukturen, die von einer Vielzahl von Autoren in verschieden vielen Schrittfolgen definiert wurden. Der etablierteste Ansatz von Simon (erweitert nach LAUDON) unterteilt den Prozess in die Schritte Intelligenz, Design, Auswahl und Umsetzung [Sim60, LL16]. Eine aggregierte Darstellung nach WISSUCHEK ET AL. unterteilt das generelle Vorgehen in die **Evaluation von Alternativen**, den eigentlichen **Entscheidungsprozess** sowie den Vorgang der **Anpassung** und des **Lernens** (vgl. Bild A-3).



*Bild A-3: Aggregierte Darstellung der Phasen des Entscheidungsfindungsprozesses in Anlehnung an [WZ23]*

Darauf aufbauend beschreibt die **datengetriebene Entscheidungsfindung** (aus dem Englischen: *Data-Driven-Decision-Making*) die Verwendung von Daten und Metriken als Entscheidungsgrundlage. Es werden Ansätze wie statistische Analysen, Datenvisualisierung und Vorhersage von Parametern zur Entscheidungsfindung eingesetzt [KSM23, S. 13]. Alle Begriffe haben im Kern den Begriff der Entscheidung – diese soll für das gezielte Einleiten einer Aktion herbeigeführt werden. **Entscheidungen als Symbiose** von Menschen und KI-Anwendung werden im Unternehmenskontext immer üblicher (siehe Kapitel 2.4.1). Dabei betont JARRAHI die Rolle von drei Mechanismen welche eine Kombination von humanbasierten und KI-Entscheidungsprozessen als Vorteilhaft darstellt (vgl. Bild A-4) [Jar18, S. 577].

- A3) **Ungewissheit** (Unklare Rahmenbedingungen): Hierbei dominiert der Mensch insbesondere darin, rasche, intuitive Entscheidungen aufbauend auf einer unbekanntem oder unklaren Sachlage zu treffen. Maschinell basierte Verfahren können durch den Zugang zu einer großen Menge von Echtzeitinformationen mit einem Faktor an Ungewissheit umgehen. [Jar18]
- A4) **Komplexität** (Komplexe Sachverhalte): Der menschliche Entscheider dominiert durch die Fähigkeit effektiv die Menge an relevanten Daten vorab zu filtern. Entscheidungen unter Auswahl Faktoren ähnlicher Wertigkeit können rasch getroffen werden. Maschinell basierte Verfahren können insbesondere durch die Fähigkeit große Datenmengen zu verarbeiten und zu analysieren profitieren. [Jar18]

A5) **Äquivokalität** (Handeln und Entscheiden im Kontext): Der Kontext kann durch den menschlichen Entscheider insbesondere in Gruppendynamiken gewinnbringend eingesetzt werden. Maschinelle Verfahren basieren primär auf der Fokussierung auf die Analyse von Verhaltensmustern. [Jar18]

**Es lässt sich festhalten:** Die Mensch-KI-Symbiose dient dem zweckdienlichen Design von Entscheidungsprozessen. Der Faktor Mensch brilliert durch Intuition und Entscheidungsgewalt. Eine KI-gestützte Anwendung kann bei der Analyse und Sammlung von Daten Verbesserungspotenziale im Entscheidungsprozess freisetzen. [Jar18, S. 583]



	Ungewissheit	Komplexität	Äquivokalität
<b>Entscheider</b> 	Rasche, intuitive Entscheidungen angesichts des Unbekannten treffen	Entscheiden, wo Daten zu suchen sind. Wählen zwischen Optionen mit gleicher Wertigkeit	Verhandeln, Konsens schaffen und Unterstützung gewinnen
<b>KI</b> 	Zugang zu Echtzeitinformationen (z. B. Erkennung von Anomalien)	Sammeln, Aufbereiten, Verarbeiten und Analysieren von Daten	Analysieren von Stimmungen und aufzeigen verschiedener Interpretationen

Bild A-4: Mensch-KI-Symbiose und Dimensionen der Unterschiedlichen Ausprägungen in der Entscheidungsfindung in Anlehnung an [Jar18, S. 583]

### A1.4 Daten für Industrial Data Science

Die folgende Tabelle A-2 gibt einen detaillierten Überblick zu den Herausforderungen aus Tabelle 2-3 der Problemanalyse.

Tabelle A-2: Übersicht über datenpoolrelatierte Herausforderungen in der Industrial Data Science aufbauend auf [EWB+24]

Herausforderung	Kurze Erklärung und Quelle
<b>Vielfalt</b> bei den vorliegenden industriellen Daten.	<ul style="list-style-type: none"> <li>• <b>Betriebspunkte mit gleichen Daten:</b> In der Industrie werden Maschinen und Anlagen normalerweise im Normalzustand (Betriebspunkt) betrieben. Daten über fehlerhafte Zustände sind schwer zu erhalten, was zu einer geringen Datenvielfalt führt und das Trainieren von Modellen zur Fehlererkennung, -vorhersage oder -diagnose erschwert. [CLX+22]</li> <li>• <b>Fehlende Incentives zum Erzeugen von Fehlerdaten:</b> Die Erzeugung ausreichender Daten die für Predictive Maintenance (Fehlerdaten/Crashdaten) liegt nicht im Interesse des Betreibers. Dies würde voraussetzen, dass es überhaupt zu regelmäßigen Fehlern in heutzutage bereits gut durchoptimierten Anlagen kommt. [EWB+24]</li> </ul>

<p>Mangel an ausreichenden (gelabelten) Daten [FMB+20, MFK+22]</p>	<ul style="list-style-type: none"> <li>• <b>Identifikation:</b> Im Zusammenhang mit der Industrie, dem Internet der Dinge (IoT) und cyber-physischen Systemen wird in der Literatur oft über Big Data gesprochen [LTC+15, YK15] Dies setzt aber neue und fortschrittliche Prozesse voraus. In der Praxis beklagen die Unternehmen jedoch häufig ein Datendefizit [MFK+22]. Ohne vollständige Datenlage können Analytics und KI Use Cases auch nicht gewinnbringend eingesetzt werden [DKM89]. Oftmals geht es eher darum die Richtigen Daten zu haben und im vorhandenen Datenbankschema zu identifizieren [Sie23, LMK21, WWS+24, S. 3].</li> <li>• <b>Zugänglichkeit:</b> Dieses Problem tritt auf, weil viele Produkte im Feldeinsatz nicht über genügend Sensoren verfügen oder der Datenzugriff durch unzureichende Netzwerkverbindungen behindert wird. Selbst wenn große Datenmengen verfügbar sind, mangelt es oft an kommentierten Daten, oder es ist nur eine begrenzte Menge zugänglich, da die Datenkommentierung kostspielig und zeitaufwändig ist. [FCW+21].</li> <li>• <b>Übertragbarkeit:</b> Insbesondere bei neuen Prozessen welche keine Historischen Daten generiert haben treffen existierende Ansätze ohne exzellente Transferierbarkeit auf ihre Grenzen [LYH+19, S. 293].</li> <li>• <b>Standardisierung:</b> Definition der Granularität und Qualität der Daten stellt eine bleibende Herausforderung dar [HHS24, S. 56].</li> </ul>
<p>Variation in industriellen Daten</p>	<ul style="list-style-type: none"> <li>• <b>Industriedaten:</b> Diese können nach sehr unterschiedlichen Merkmalen klassifiziert werden. Zum einen können die Quellen nach ihrer Herkunft im Unternehmen betrachtet werden, d.h. aus einer organisatorischen und bereichsbezogenen Perspektive. Sie werden zum Beispiel in verschiedenen Geschäftsbereichen wie Marketing und Entwicklung und entlang verschiedener Schritte des Produktlebenszyklus erzeugt. [PEM+22]</li> </ul>
<p>Aufwände für das Datenmanagement</p>	<ul style="list-style-type: none"> <li>• <b>Unklarer Datenmehrwert:</b> Ein Mangel an Governance und Abstraktionsebenen im Datenmanagement führt zu einem Verlust an Datenanalysepotenzial. [EWB+24]</li> <li>• <b>Nützlichkeit der Daten:</b> Datenqualität und Datenmenge sind immer noch große Herausforderungen. Das gilt vor allem für das Nichtvorhandensein von Daten. Das Wissen um die richtigen Daten für die jeweilige Geschäftsfrage ist immer noch eine Herausforderung. Um Daten über Fehler zu sammeln, muss ein Fehler auftreten. Mit anderen Worten: Man braucht Daten für die Frage, die man sich stellt (z. B. Predictive Analytics). [EWB+24]</li> <li>• <b>Data Governance:</b> Data Lineage, Datentransparenz, Interkonnektivität: Die Integration von Datenpools ist eine ständige Herausforderung. [EWB+24, WWS+24, S. 3]</li> <li>• <b>Datenermittlung:</b> Das Matchen von Daten und Use Case ist immer noch eine Herausforderung. [EWB+24]</li> </ul>

## A1.5 Sammlung von Prescriptive Analytics Use Cases

Im Folgenden werden Tabellen für die untersuchte Literatur aus dem Stand der Technik und für Use Cases, Plattformen und Referenzarchitekturen aus der Recherche aus [WMN+24] bereitgestellt (siehe Tabelle A-3).

*Tabelle A-3: Literaturschlüssel: Prescriptive Analytics Use Cases in der Produktion*

Use Case 01	[SPB+19]	Use Case 19	[VHK19a]*
Use Case 02	[BSK+15]	Use Case 20	[FK21]
Use Case 03	[TW18]	Use Case 21	[VHK19b]
Use Case 04	[GNL23]	Use Case 22	[MMM20]
Use Case 05	[ELM+22]	Use Case 23	[KK22]
Use Case 06	[CBJ20]	Use Case 24	[AGN19]
Use Case 07	[MNK+17]	Use Case 25	[PLN+21]
Use Case 08	[BPM+20]	Use Case 26	[LPB+20]
Use Case 09	[SVA+22]	Use Case 26	[KAG19]
Use Case 10	[SS16]	Use Case 27	[HSN+20]
Use Case 11	[JKB19]	Use Case 28	[JG19]
Use Case 12	[GBG+19]	Use Case 29	[TSH23]
Use Case 13	[AGS20]	Use Case 30	[Das13]
Use Case 14	[LFR+21]	Use Case 31	[MS23]
Use Case 15	[ABO+17]	Use Case 32	[SBA+22]
Use Case 16	[JQH16]	Use Case 33	[Grö18]
Use Case 17	[SMF18]	Use Case 34	[BRH+20]
Use Case 18	[VSK+19]		

\* Das Paper beschreibt einen Use Case, präsentiert aber gleichzeitig auch eine Plattform und wird daher an zwei Stellen im Rahmen der Ausarbeitung bewertet und integriert.

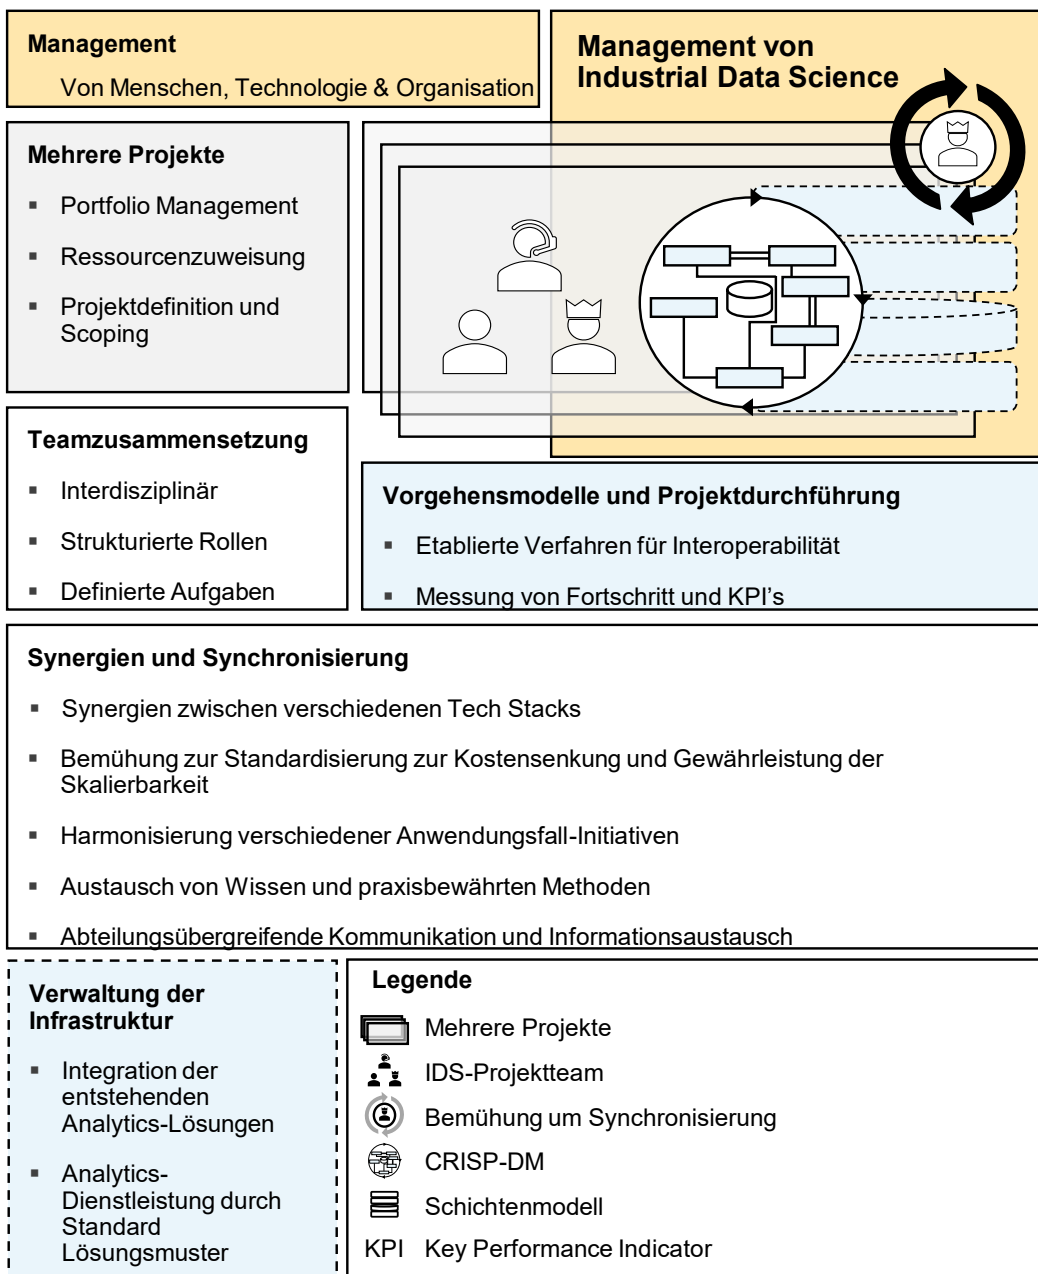
## A2 Ergänzungen zur Spezifikationstechnik

Das Kapitel gibt einen Überblick über Ergänzungen zur Spezifikationstechnik.

### A2.1 Rahmenwerk für Industrial Data Science

Im Folgenden wird das bereits in Kapitel 4.3 vorgestellte Rahmenwerk für das Management von Analytics Use Cases in der Produktion um eine detaillierte Darstellung mit Fokusthemen ergänzt (vgl. Bild A-5).

*Bild A-5: Rahmenwerk für das Management von Industrial Data Science (statische Sicht) aufbauend auf [EWB+24]*



## A2.2 Design Prinzipien für Prescriptive Analytics Use Cases

Das Kapitel stellt die ausführliche Erläuterung der Design Prinzipien für Prescriptive Analytics in der Produktion bereit (siehe Tabelle A-3).

Tabelle A-4: Design Prinzipien für Prescriptive Analytics Use Cases in der Produktion

Design Prinzip	Erläuterung
DP1: Datenerfassung und Modellbildung	<b>Verwende Metriken, die auf den Prinzipien der Bounded Rationality (siehe Kapitel 2.1.3) beruhen:</b> Die Metriken zur Bewertung der Funktionalität von Prescriptive Analytics Use Cases müssen auf die Einschränkungen abgestimmt werden, die sich aus den Entscheidungen und Handlungsempfehlungen einer realen Produktionsumgebung ergeben. Ihre Optimalität ist schwer zu messen und sollte nach ihrer subjektiven Qualität bewertet werden. Das bedeutet, dass die Zeit, die Informationen und die kognitiven Fähigkeiten des Entscheidungsträgers, der normalerweise die Entscheidung trifft, berücksichtigt werden müssen („Human Baseline“).
DP2: Aufwandsreduzierung bei der Umsetzung	<b>Bereits formalisiertes Wissen im Unternehmen nutzen</b> (siehe Kapitel 2.3): Bestehende Unternehmensdokumente sollten als wertvollen kognitiven Input für die Prescriptive Analytics Use Cases genutzt werden. Der Schwerpunkt liegt auf der Wissensaggregation und der Sicherstellung eines Return on Investments für den Use Case. Der Umsetzer sollte ermutigt werden, vorhandene Unternehmensdokumente zu nutzen und in den Prescriptive Analytics Use Case zu integrieren. Ziel ist es, Wissen aus verschiedenen Quellen zu sammeln, um die Skalierbarkeit zu erhöhen und den Aufwand (Face-to-Face Kommunikation und Workshops) zu verringern.
DP3: Mensch-Analytics Interaktion	<b>Anpassen des Use Case Automatisierungsgrades:</b> Erkenne, dass eine End-to-End Automatisierung nicht immer der beste Reifegrad für die Umsetzung des Use Cases ist (siehe Kapitel 2.4.2). Eine Entscheidungssymbiose zwischen Menschen und Prescriptive Analytics Use Case sollte gefördert werden. Eine symbiotische Beziehung, in der Mensch und Analytics Lösung ihre jeweiligen Stärken für eine optimale Entscheidungsfindung nutzen bietet sich an (Komplexität, Unsicherheit, Equivokalität (siehe Kapitel A1.2)).
DP4: Industrie 4.0 Fähigkeit und Kompatibilität	<b>Sicherstellung der nahtlosen Integration in bestehende Analytics basierte Optimierungsinitiativen zur Entscheidungsfindung:</b> Prescriptive Analytics muss in das Unternehmen integriert werden, indem es mit den Prinzipien von Industrie 4.0 und den kontinuierlichen Verbesserungsprozessen in Einklang gebracht wird, um organisatorisches Lernen und allgemeine Verbesserungsparadigmen für die Entscheidungsfindung zu ermöglichen (Informationstransparenz, dezentralisierte Entscheidungen, Vernetzung, technische Unterstützung).
DP5: Analytics Insights nutzen	<b>Fokus auf Actionable Decisions:</b> Verlagerung des Schwerpunkts auf umsetzbare Entscheidungen statt nur auf Vorhersagen und Visualisierungen. Fördern einer Denkweise, die den Gedanken der Vorgabe von Maßnahmen in allen Analytics Use Cases, die umgesetzt werden sollen, betont. Es gibt keinen rein Prescriptive Analytics Use Case. Alle analytisch gewonnenen Erkenntnisse können durch Prescriptive Analytics spezifische Aspekte ergänzt werden (siehe Kapitel 2.4).

<b>DP6: Erfolgsfaktoren für die Umsetzung</b>	<b>Entscheidungskonnektivität fördern und Silo-Installationen vermeiden:</b> Stelle Verbindungen zwischen verschiedenen Use Cases und Analyseansätzen her. Dies schafft die Möglichkeit zum Datenaustausch und zur Interoperabilität. Andere Analytics Use Cases können als wertvoller Input dienen. Die Nutzung von Vorhersagen und Erkenntnissen aus verschiedenen Analytics Use Cases sollte als Input für Prescriptive Analytics verwendet werden.
---	---

### A2.3 Subkategorien der Taxonomie für Prescriptive Analytics Use Cases

Im Folgenden wird ein Überblick zu den einzelnen Kategorien der Prescriptive Analytics Use Case Taxonomie gegeben (siehe Tabelle A-6).

Tabelle A-5: Subelemente der Prescriptive Analytics Use Case Taxonomie

Kategorie	Sub-kategorie	Sub-Subkategorie
Problemstellung	Ziel KPI	<ul style="list-style-type: none"> <li>• <b>Verfügbarkeit:</b> Maß für die Fähigkeit eines Systems oder einer Komponente, zu einem gegebenen Zeitpunkt betriebsbereit zu sein und den geforderten Dienst zu erbringen.</li> <li>• <b>Qualität:</b> Grad, in dem ein Satz inhärenter Merkmale Anforderungen erfüllt. Indikator für die Beschaffenheit eines Produkts oder Prozesses hinsichtlich Fehlerfreiheit und Eignung für den vorgesehenen Zweck.</li> <li>• <b>Leistung:</b> Effizienz und Effektivität, mit der ein System oder Prozess seine Funktionen ausführt, oft gemessen durch Durchsatz, Geschwindigkeit oder Ressourcenverbrauch.</li> </ul>
	Problemhäufigkeit	<ul style="list-style-type: none"> <li>• <b>Wiederkehrend:</b> Probleme, die in regelmäßigen oder unregelmäßigen Abständen erneut auftreten und daher systematische Lösungen erfordern.</li> <li>• <b>Einmalig:</b> Probleme, die nur einmal auftreten und spezifische, individuelle Lösungsansätze benötigen.</li> <li>• <b>Fortlaufend:</b> Probleme, die kontinuierlich vorhanden sind und dauerhaft überwacht werden müssen.</li> </ul>
	Echtzeitfähigkeit	<ul style="list-style-type: none"> <li>• <b>Direkte Auswirkung:</b> Effekt, der unmittelbar nach einer Handlung oder Entscheidung auftritt und sofortiges Eingreifen erfordert.</li> <li>• <b>Langzeitauswirkung:</b> Effekte, die sich über einen längeren Zeitraum manifestieren und langfristige Strategien zur Bewältigung erfordern.</li> <li>• <b>Vernachlässigbare Auswirkung:</b> Effekte, deren Einfluss auf das Gesamtsystem minimal ist und die daher keine unmittelbaren Maßnahmen notwendig machen.</li> </ul>

	<b>Art des Auslösers</b>	<ul style="list-style-type: none"> <li>• <b>Anomaliedetektion:</b> Identifikation von Abweichungen oder Unregelmäßigkeiten innerhalb von Daten oder Prozessen.</li> <li>• <b>Menschliche Intervention:</b> Auslösung von Prozessen oder Entscheidungen durch direkte Eingaben oder Aktionen von Personen.</li> <li>• <b>Zustandsinformation</b> (ereignisbasierter Auslöser): Aktivierung durch spezifische Zustände oder Ereignisse im System, die vordefinierte Schwellenwerte oder Kriterien erfüllen.</li> </ul>
<b>Geschäftsfelder</b>	<b>Domäne</b>	<ul style="list-style-type: none"> <li>• <b>Ressourcen:</b> Maschinen, Werkzeuge oder Personal, die für die Produktion erforderlich sind.</li> <li>• <b>Produkt:</b> Das finale Erzeugnis oder Teilerzeugnis eines Produktionsprozesses, welches bestimmte Spezifikationen erfüllen muss.</li> <li>• <b>Überwachender Prozess:</b> Systeme oder Verfahren, die zur Kontrolle und Steuerung von Produktionsabläufen eingesetzt werden.</li> <li>• <b>Betrieb:</b> Aktivitäten zur Leistungserstellung innerhalb der Produktion.</li> <li>• <b>Umfeld:</b> Externe Faktoren und Bedingungen, die die Produktionsprozesse beeinflussen, wie Marktbedingungen oder regulatorische Anforderungen.</li> </ul>
	<b>Auswirkungsbereich</b>	<ul style="list-style-type: none"> <li>• <b>Fabrik:</b> Physischer Standort, an dem Produktionsprozesse stattfinden, einschließlich aller infrastrukturellen Einrichtungen.</li> <li>• <b>Produktionseinheit:</b> Einzelne funktionale Einheit innerhalb der Fabrik, die spezifische Aufgaben im Produktionsprozess übernimmt.</li> <li>• <b>Produktionslinie:</b> Sequenz von Arbeitsschritten oder Stationen, durch die ein Produkt in einer festgelegten Reihenfolge bearbeitet wird.</li> <li>• <b>Produktionszelle:</b> Gruppe von Maschinen oder Arbeitsplätzen, die räumlich und funktional zusammengefasst sind, um gemeinsame Aufgaben zu erfüllen.</li> <li>• <b>Untergeordnete Einheit der Zelle:</b> Kleinste funktionale Einheit innerhalb einer Produktionszelle, z. B. einzelne Maschinen oder Roboter.</li> <li>• <b>Wertschöpfungsnetzwerk:</b> Vernetztes System verschiedener Organisationen und Prozesse, die gemeinsam zur Wertschöpfung des Endprodukts beitragen.</li> </ul>
<b>Entscheidungstyp</b>	<b>Entscheidungsstrategie</b>	<ul style="list-style-type: none"> <li>• <b>Konkurrierend:</b> Entscheidungsstrategien, bei denen mehrere Optionen oder Systeme um Ressourcen oder Priorität konkurrieren.</li> <li>• <b>Einzel:</b> Entscheidungsfindung, die isoliert und unabhängig von anderen Entscheidungen oder Systemen erfolgt.</li> </ul>

	<b>Ansatz der Entscheidung</b>	<ul style="list-style-type: none"> <li>• <b>Reaktiv:</b> Ansatz, bei dem Entscheidungen als Reaktion auf eingetretene Ereignisse oder Zustände getroffen werden.</li> <li>• <b>Proaktiv:</b> Ansatz, der darauf abzielt, durch vorausschauende Maßnahmen zukünftigen Ereignissen oder Zuständen vorzubeugen.</li> </ul>
<b>Input</b>	<b>Datenquelle</b>	<ul style="list-style-type: none"> <li>• <b>Standortdaten:</b> Informationen über geografische Positionen von Ressourcen, Anlagen oder Produkten innerhalb der Lieferkette oder Produktion.</li> <li>• <b>Produktdaten:</b> Daten, die spezifische Merkmale, Spezifikationen oder den Zustand von Produkten beschreiben.</li> <li>• <b>Wartungsdaten:</b> Aufzeichnungen über durchgeführte oder geplante Instandhaltungsmaßnahmen an Maschinen und Anlagen.</li> <li>• <b>Operative Daten:</b> Laufende Informationen über aktuelle Produktionsprozesse, einschließlich Leistungskennzahlen und Statusberichte.</li> <li>• <b>Objektdaten:</b> Daten, die physische Gegenstände innerhalb des Produktionsprozesses beschreiben, wie z. B. Teile oder Komponenten.</li> <li>• <b>Kundendaten:</b> Informationen über Kundenanforderungen, Bestellungen und Feedback, die für die Produktionsplanung relevant sind.</li> <li>• <b>Daten zur Lieferkette:</b> Informationen über Lieferanten, Logistik, Lagerbestände und Materialflüsse innerhalb der gesamten Lieferkette.</li> <li>• <b>Qualitätsdaten:</b> Messwerte und Berichte, die die Qualität von Produkten oder Prozessen quantifizieren und bewerten.</li> <li>• <b>Materialflussdaten:</b> Daten über die Bewegung und Handhabung von Materialien und Komponenten der Produktion.</li> </ul>
	<b>Umgebung</b>	<ul style="list-style-type: none"> <li>• <b>Deskriptive Daten:</b> Daten, die den aktuellen Zustand von Systemen oder Prozessen beschreiben, ohne Ursache-Wirkungs-Beziehungen aufzuzeigen.</li> <li>• <b>Diagnostische Daten:</b> Daten, um Ursachen für aufgetretene Ereignisse oder Zustände zu identifizieren und zu analysieren.</li> <li>• <b>Prädiktive Daten:</b> Daten, die Prognosen über zukünftige Zustände oder Ereignisse ermöglichen.</li> <li>• <b>Präskriptive Daten:</b> Daten, die konkrete Handlungsempfehlungen oder Entscheidungen bereitstellen, beispielsweise aus anderen getroffenen Entscheidungen.</li> </ul>

<p><b>Output</b></p>	<p><b>Mensch-Algorithmus-Interaktion</b></p>	<ul style="list-style-type: none"> <li>• <b>Decision Support:</b> Systeme oder Ansätze, die Entscheidungsträgern Informationen bereitstellen, um Entscheidungen treffen zu können.</li> <li>• <b>Decision Augmentation:</b> Erweiterung der menschlichen Entscheidungsfindung durch algorithmische Empfehlungen, wobei der Mensch die finale Entscheidung trifft.</li> <li>• <b>Decision Automation:</b> Vollständige Automatisierung von Entscheidungsprozessen durch Algorithmen ohne direkte menschliche Intervention.</li> </ul>
----------------------	--	--

## A2.4 Meta-Rec recommender Ansatz für Prescriptive Analytics Use Cases

Um den präskriptiven Charakter einer Use Case Wissensdatenbank zu gewährleisten (aufbauend auf einer Taxonomie), wird auf einen konzeptionellen Ansatz zur Erstellung eines Meta-Rec recommenders für Use Case Entwicklungsvorhaben zurückgegriffen. Ein Meta-Rec recommender soll auf Basis der Ähnlichkeit der Problemstellung anderer (bereits implementierter und dokumentierter) Use Cases mögliche Implementierungsmuster empfehlen. Dieser Ansatz soll im Folgenden erläutert werden. Damit soll die Lücke zwischen Forschung und umsetzbaren Implementierungen in der Industrie überbrückt werden. Eine weitere Möglichkeit, ein solches System zu realisieren, wäre die Verwendung der Taxonomie zur Ableitung von Mustern für Prescriptive Analytics Use Cases [Zsc23]. Die allgemeine Idee eines Meta-Rec recommenders ist in Bild A-6 visualisiert.

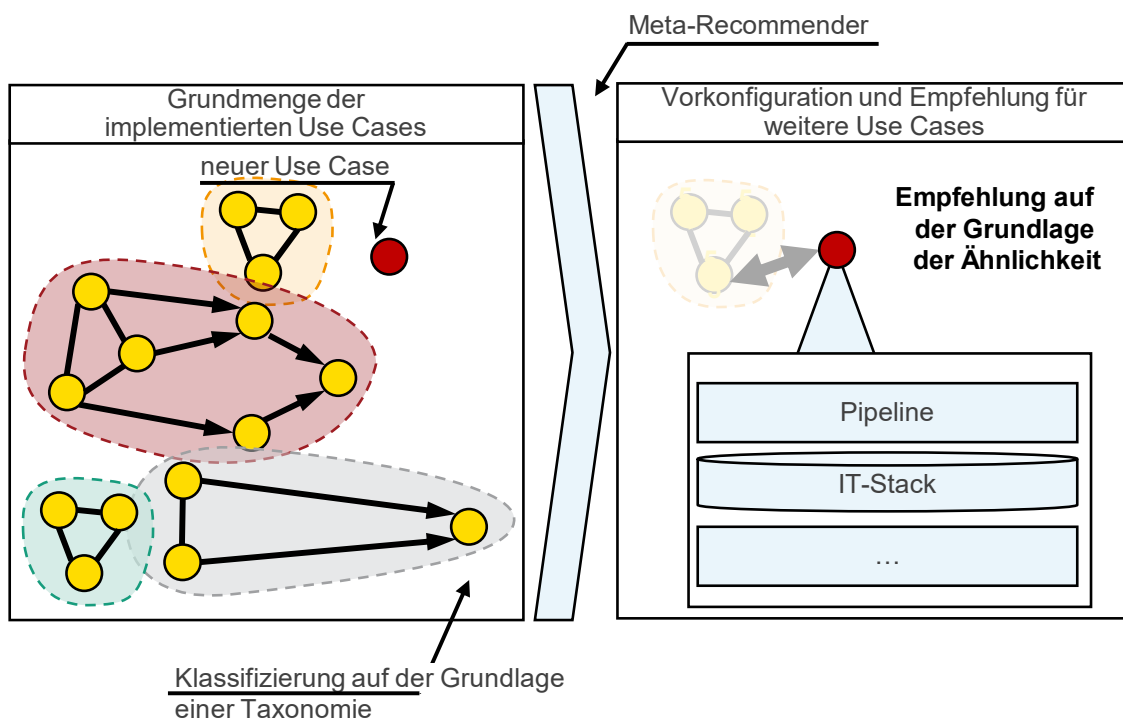


Bild A-6: Konzept des Meta Rec recommenders für Prescriptive Analytics Use Cases in der Produktion aufbauend auf [WNG+25]

Lösungsmuster für die Implementierung von Prescriptive Analytics, mögliche Aktionen auf Basis der Vorgaben und mögliche Unsicherheiten und Risiken können auf Basis der Ähnlichkeit zwischen Use Cases abgebildet werden. In diesen Fällen ist insbesondere das Ähnlichkeitsmaß entscheidend, um eine effiziente Ableitung von sinnvollen Ähnlichkeiten zu gewährleisten [MKD23, S. 144].

### A2.5 Mapping von Concerns und Partialmodellen

Aufbauend auf der ISO/IEC/IEEE 42010:2022 [IEC42010] wird der Bedarf für die einzelnen Partialmodelle (model kinds) aus den Viewpoints (Perspektiven) und Views (Sichten) der relevanten Stakeholder und deren Concerns abgeleitet. Ein komprimierter Überblick dieser Herleitung ist Bild A-7 und Bild A-8 zu entnehmen.

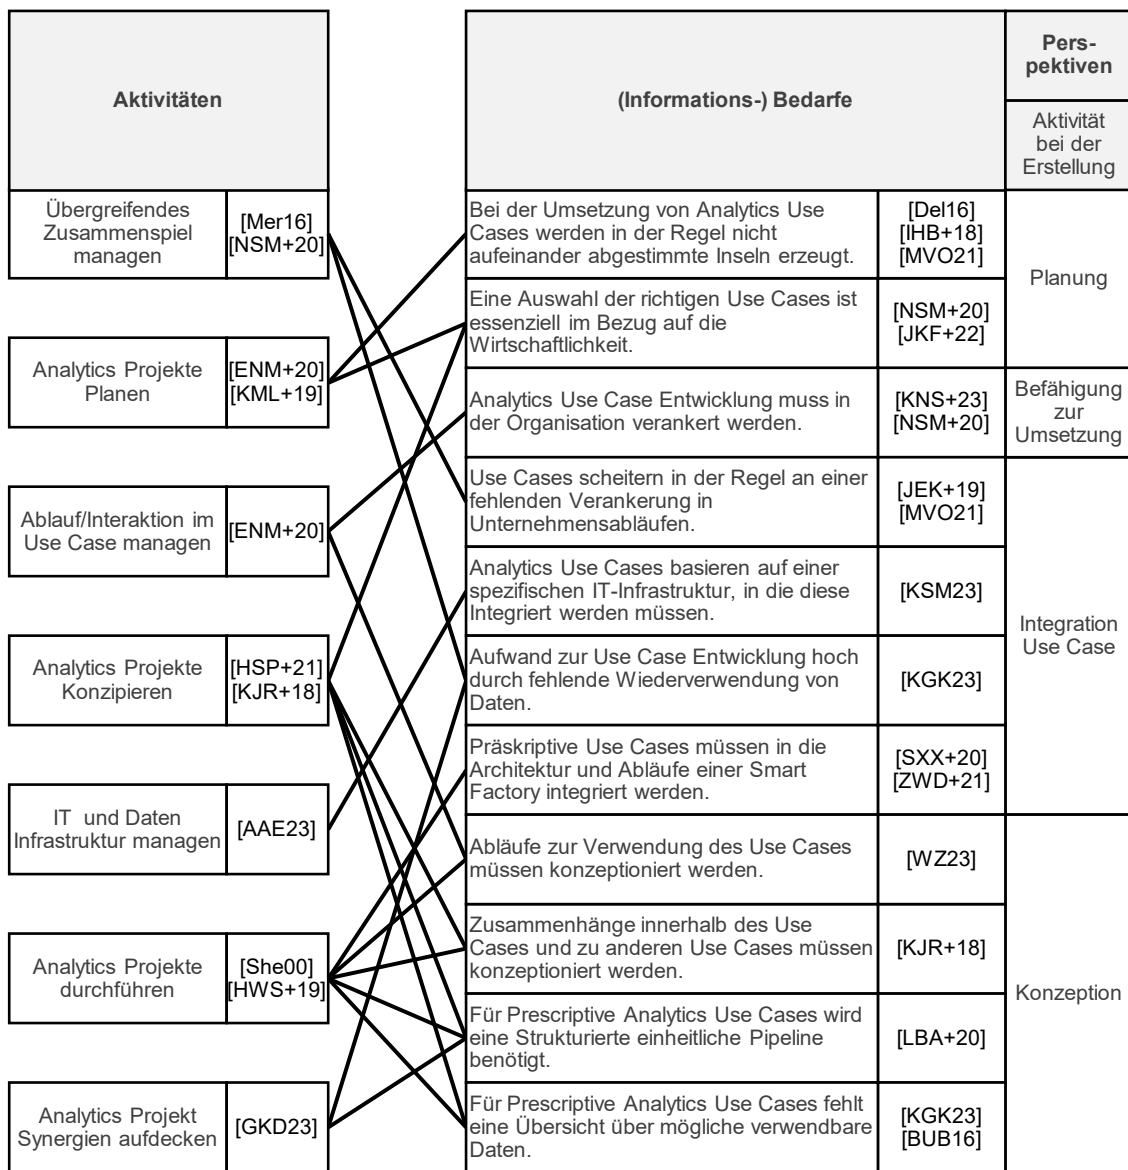


Bild A-7: Zusammenhänge zwischen Aktivitäten, Informationsbedarfen und Perspektiven der Spezifikationstechnik (aufbauend auf [IEC42010])




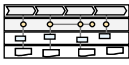
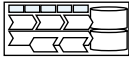
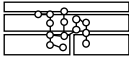
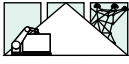
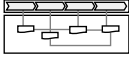
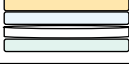


Perspektiven		Partialmodelle		
Aktivität bei der Erstellung	Zweck	Beschreibung		
Planung	Roadmap zur zeitlichen Abfolgeplanung der Implementation der Use Cases	Planung	Datenobjektbasierte Roadmap	
	Portfolio zur Bewertung und Auswahl der relevanten Use Cases	Konsolidierung	Aufwand-Nutzen-Portfolio	
Befähigung zur Umsetzung	Fähigkeiten der Organisation für Advanced Analytics	Fähigkeiten	Capabilities für Prescriptive Analytics in Smart Factories	
Integration Use Case	Einbettung der Use Cases in die Organisation (Prozess)	Prozess	Use Case Abhängigkeit Entlang des Prozesses	
	Einbettung der Use Cases in die IT-Infrastruktur (Applikation)	Applikation	Overall Tech Stack/Plattform	
	Einbettung der Use Cases Daten in die Unternehmensdatenontologie (Daten)	Daten	Company Wide Data Ontology	
	Einbettung der Use Cases in die Fabrik (Techn. Architektur/Fabrik)	Architektur	Referenzarchitektur zur Integration in die Fabrik	
Konzeption	Konzeptionieren der Analytics Use Case Interaktion (Prozess)	Prozess	Decision Data Map (Verwendung)	
	Konzeptionieren der Analytics Use Case Architektur (Applikation)	Architektur	Analytics Schichtenmodell	
	Konzeptionieren der Analytics Use Case Pipeline (Techn. Architektur)	Applikation	Prescriptive Analytics Pipeline	
	Konzeptionierung der Prescriptive Analytics Use Case Daten	Daten	Use Case Data Layers	

Bild A-8: Zusammenhänge zwischen Perspektiven und Partialmodellen der Spezifikationstechnik (aufbauend auf [IEC42010])

## A2.6 Ergänzende Informationen zum Metamodell

Die im Folgenden abgebildete Darstellungskonvention kann als Workshopkarte verwendet werden. Die Darstellungskonvention orientiert sich am EAM-ArchiMate Metamodell Standard. Er dient als Empfehlung und kann firmen- oder werkzeugspezifisch an die Bedarfe angepasst werden (z. B. Metamodellkonfiguration in LeanIX). Bild A-9 gibt einen Überblick über die zugelassenen Verbindungen zwischen den Modellierungselementen der Spezialisierung der Spezifikationstechnik.

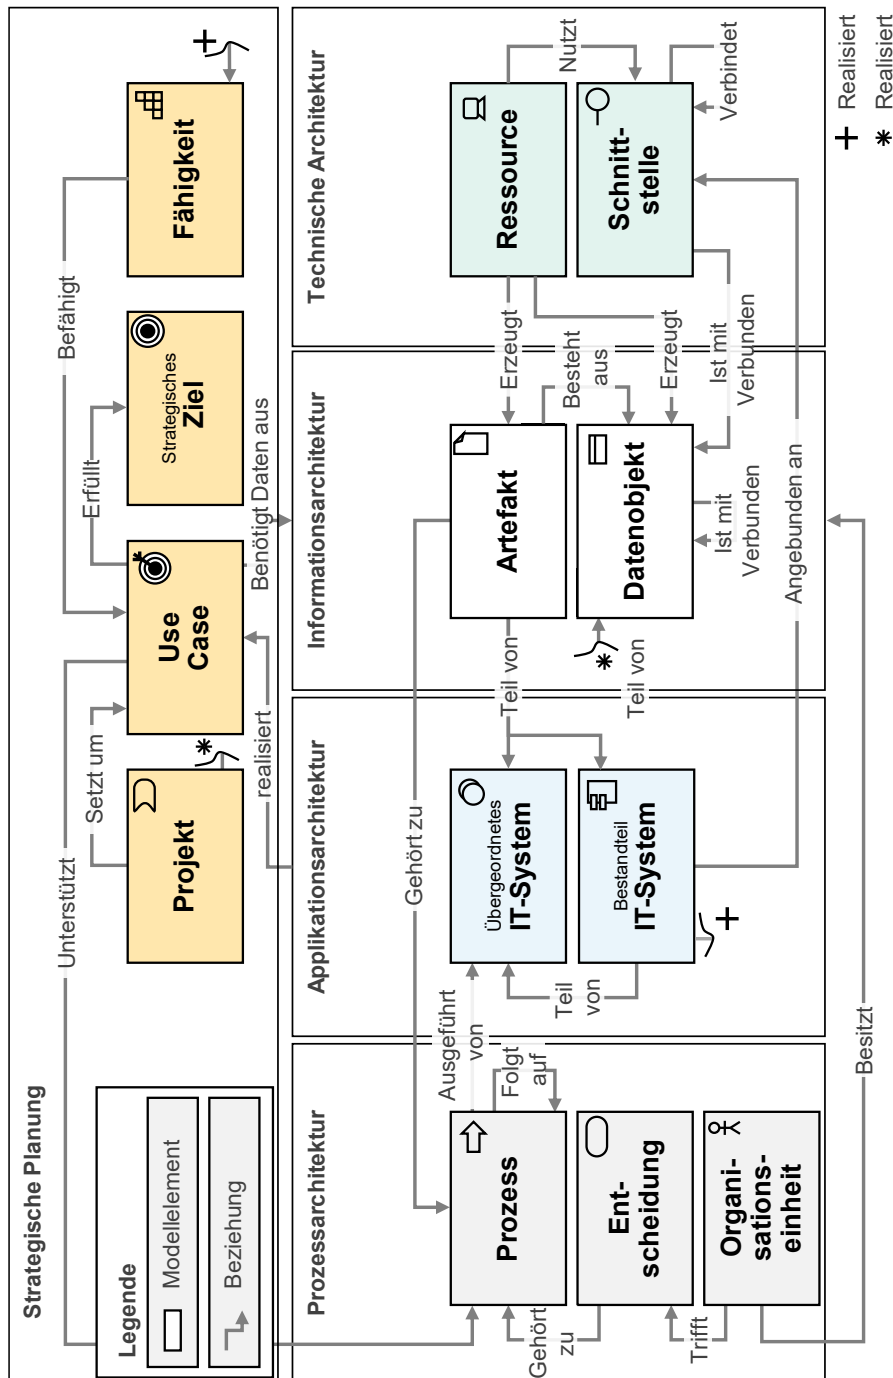
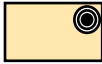

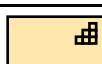
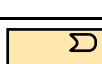

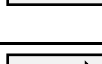

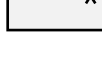


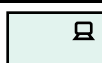
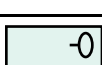



Bild A-9: Spezialisierung des Metamodells für die Ausarbeitung

Eine kurze Erläuterung der Modellelemente der Spezialisierung wird in Tabelle A-6 zur Verfügung gestellt. Die Farben orientieren sich an die im Rahmen des Modellierungskonzepts verwendeten Farben. Die folgenden Angaben sind im RGB-Farbcode dokumentiert. Die strategische Ebene wird in Gelb dargestellt (255, 231, 172). Elemente der Prozessarchitektur werden in grau visualisiert (242, 242, 242). Modellelemente der Applikationsarchitektur sind blau (234, 245, 251) darzustellen. Die Informationsarchitektur bedient sich weißer Elemente. Für die Darstellung der Elemente der technischen Architektur wird Grün (226,242,238) verwendet.

Für eine Verwendung im Workshop können die Karten zusätzlich in Rot zur Verfügung gestellt werden. Dies kann zum Anzeigen von bisher fehlenden Elementen verwendet werden. Weiterhin können Ankreuzfelder hinterlegt werden für gängige Kategorien (z. B. Typ Datenbank).

Tabelle A-6: Kurzerläuterung der Elemente der Spezialisierung

Element	Workshopkarte und Darstellungs-konvention	Kurzerläuterung
Strategisches Ziel		Ein Ziel stellt eine übergeordnete Aussage über die Absicht, die Richtung oder den gewünschten Endzustand einer Organisation und ihrer Interessengruppen dar.
Use Case		Ein Use Case ist ein Anwendungsszenario, welches das Verhalten eines Systems aus der Nutzerperspektive beschreibt.
Fähigkeit		Eine Fähigkeit stellt ein Element dar, über die ein aktives Strukturelement, wie z. B. eine Organisation, eine Person oder ein System, verfügt.
Projekt		Ein Projekt ist ein Vorgehen, das durch eine Projektorganisation gemanagt wird und am Ende dessen ein festgelegtes Werk zu erbringen ist.
Entscheidung		Eine Entscheidung stellt eine geschäftsbezogene Zustandsänderung dar.
Prozess		Ein Geschäftsprozess stellt eine Abfolge von geschäftlichen Verhaltensweisen dar, mit der ein bestimmtes Ergebnis erzielt wird, wie z. B. eine definierte Reihe von Produkten oder Geschäftsdienstleistungen.
Organisations-einheit		Eine Organisationseinheit stellt eine Geschäftseinheit dar, die in der Lage ist, ein Verhalten auszuführen.
IT-System (Übergeordnet)		IT-System ist Software, die eine Umgebung zum Speichern, Ausführen und Verwenden von Software oder Daten bereitstellt oder dazu beiträgt. Es aggregiert verschiedene IT-Systembestandteile
IT-System (Bestandteil)		IT-System (Bestandteil) ist Software, die zur Funktion des übergeordneten Systems benötigt wird.
Ressource		Eine Ressource ist ein Produktionsmittel, welches sich im Besitz oder unter der Kontrolle einer Person oder Organisation befindet.
Schnittstelle		Eine Schnittstelle stellt einen Zugangspunkt dar, über den auf Technologiedienste zugegriffen werden kann. Sie verbindet die IT- und OT-Welt sowie verschiedene IT-Systeme.
Artefakt		Ein Artefakt ist eine Sammlung der Daten, die in einem Softwareentwicklungsprozess oder beim Einsatz und Betrieb eines IT-Systems verwendet oder erzeugt werden.
Datenobjekt		Ein Datenobjekt stellt Daten dar, die für eine automatisierte Verarbeitung strukturiert sind.

Eine kurze Erläuterung der Zusammenhänge der Modellelemente der Spezialisierung wird in Tabelle A-7 zur Verfügung gestellt.

Tabelle A-7: Zugelassene Verbindungen zwischen den Modellierungselementen der Spezialisierung der Spezifikationstechnik

Zusammenhang zwischen den Elementen													
	Strategisches Ziel	Use Case	Fähigkeit	Projekt	Entscheidung	Prozess	Organisations-einheit	IT-System (Übergeordnet)	IT-System (Bestandteil)	Ressource	Schnittstelle	Artefakt	Datenobjekt
<b>Strategisches Ziel</b>													
<b>Use Case</b>	Erfüllt					Assoziiert mit							Assoziiert mit
<b>Fähigkeit</b>		Befähigt											
<b>Projekt</b>		Setzt um											Setzt um
<b>Entscheidung</b>						Gehört zu							
<b>Prozess</b>						Folgt auf		Ausgeführt von					
<b>Organisations-einheit</b>					Trifft				besitzt				besitzt
<b>IT-System (Übergeordnet)</b>		realisiert										Assoziiert mit	
<b>IT-System (Bestandteil)</b>		realisiert	realisiert								Dient		
<b>Ressource</b>											Nutzt	Erzeugt	Greift zu
<b>Schnittstelle</b>											Auslösende V./Dient		ist mit verbunden
<b>Artefakt</b>						Assoziiert mit			Assoziiert mit				Assoziiert mit
<b>Datenobjekt</b>									Teil von		ist mit verbunden		ist mit verbunden











## A2.8 Blueprints und One Pager für das Partialmodellkonzept

Blueprints sind die Partialmodelle ohne beispielhafte Modellierungselemente. Im Folgenden werden diese abgebildet (vgl. Bild A-10 bis Bild A-20) und kurz motiviert:

- **Verringerung von Aufwänden im Prozess der Konzeption:** Ein modellbasierter Ansatz ermöglicht das Wiederverwenden von Elementen und ihren Beschreibungen.
- **Traceability von Design Entscheidungen:** Die Bottom Up und Top Down Entstehung von Use Cases kann nachvollzogen werden, wenn die Modellierungsintervalle klein genug gewählt werden. Zum Beispiel die Prüfung der Strategiekonformität von Use Cases wird durch die modellbasierte Abbildung vereinfacht. So können übergreifend Entscheidungen im Use Case Entwicklungsprozess transparenter dokumentiert werden. Über die Partialmodelle hinweg kann so eine Traceability über Entscheidungen bei der Konzeption der Prescriptive Analytics Use Cases (wenn werkzeuggestützt durchgeführt) aufwandsarm angestrebt werden. Aspekte der Dokumentation der Designentscheidung werden nicht von dieser Ausarbeitung weiter detailliert und bieten Potenzial für weitere Forschung.
- **Erhöhen der allgemeinen Ergebnisqualität bei der Konzeption:** Der Anwender wird befähigt, Synergien aufzudecken. Weiterhin können editierbare Inhalte zielgerichtet geteilt werden. Quantitative Analysen und Auswertungen sind durch den Charakter eines Modells möglich. Abhängigkeiten (Dependencies) können gemanagt werden (vgl. Ansätze aus dem MBSE [HKD20]). Wissen kann gezielt aggregiert werden. Eine Anpassung des Detaillierungsgrades an die anwesenden Stakeholder wird ermöglicht (Abstraktionsgrad zielgruppengerecht wählen) [Rei13].
- **Komplexitätsmanagement und Kooperation:** Durch das Verwenden eines werkzeuggestützten Konzepts steigt der Grad der wiederverwendbaren Teilbestandteile. Ein Übertrag zu anderen Konzeptionsvorhaben durch das Modell wird möglich.

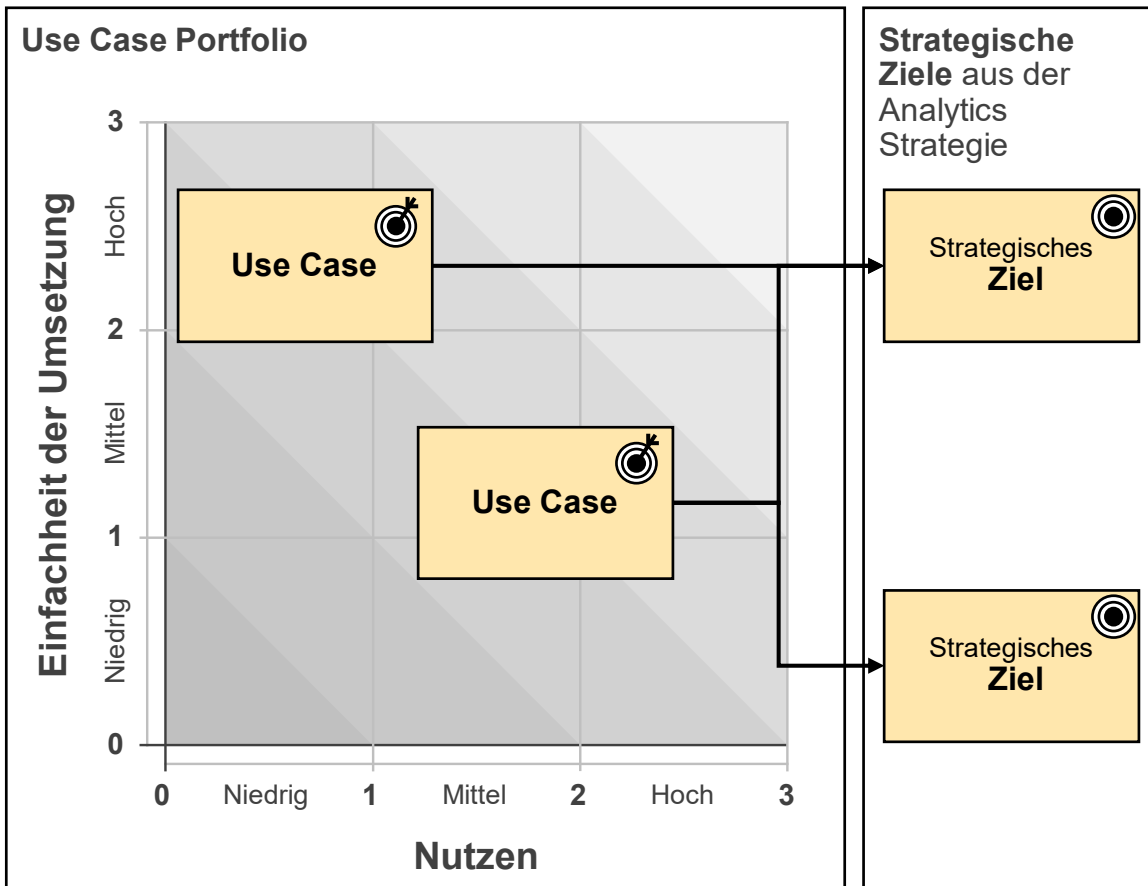


Bild A-10: Blueprint für das Partialmodell des Analytics Portfolios

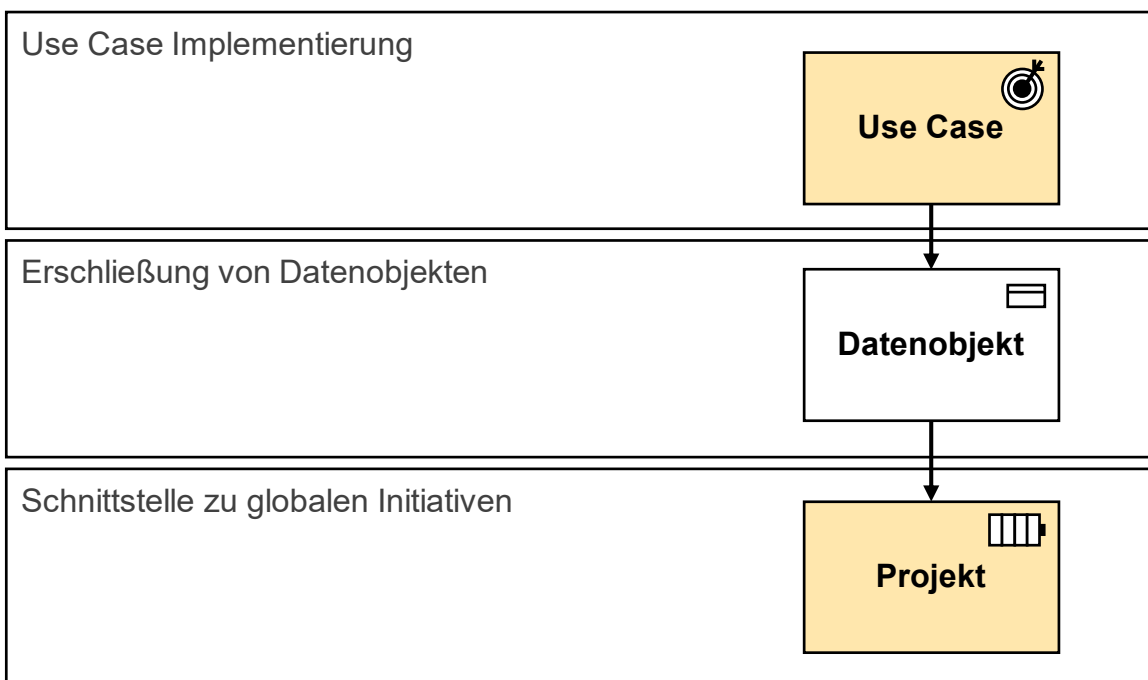


Bild A-11: Blueprint für das Partialmodell der Roadmap

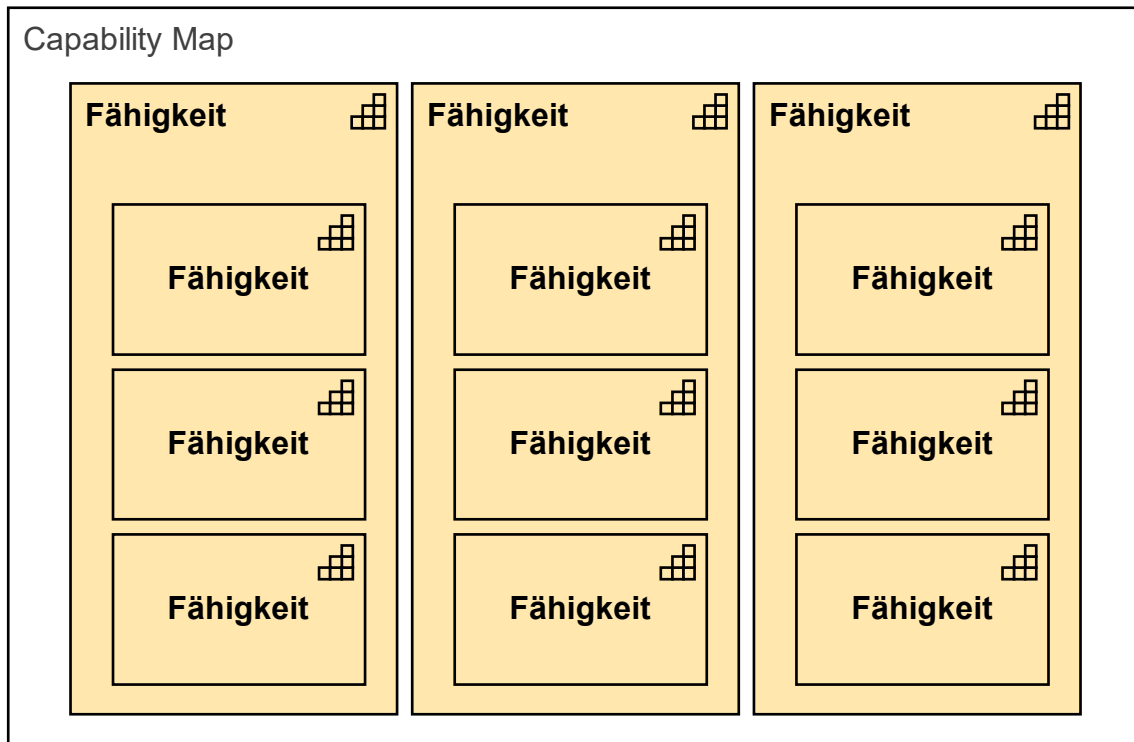


Bild A-12: Blueprint für das Partialmodell der Capability Map

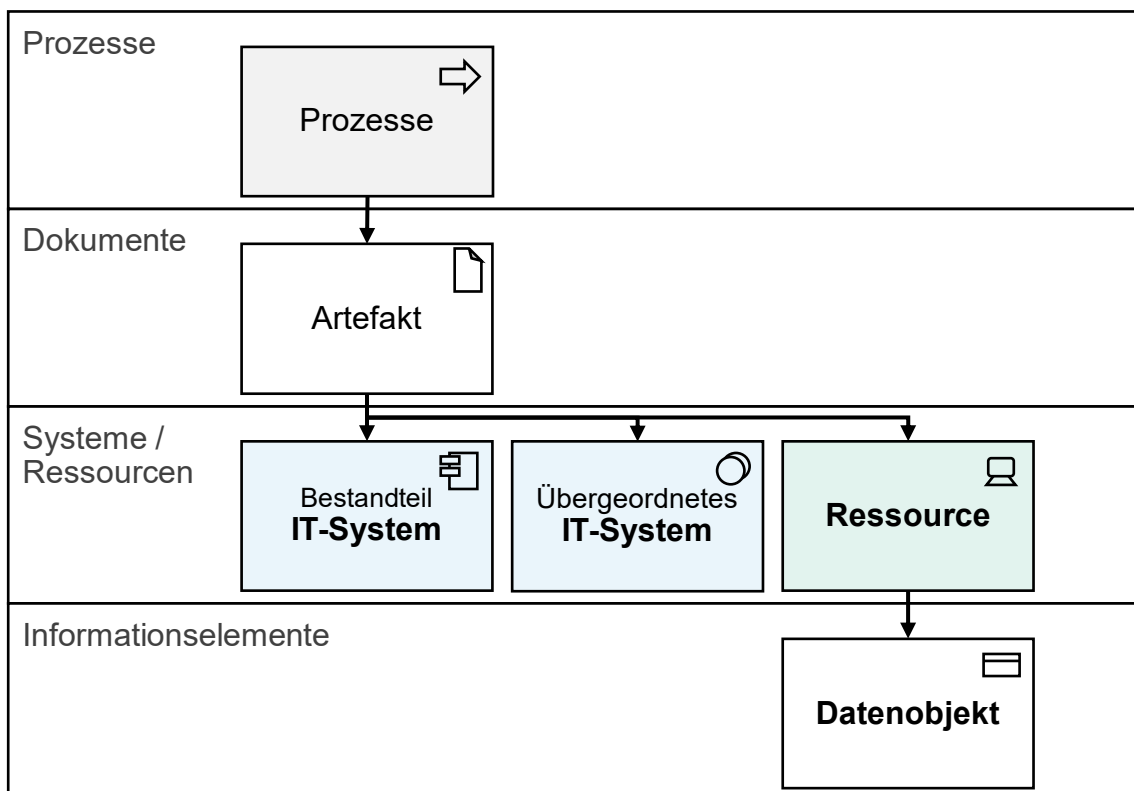


Bild A-13: Blueprint für das Partialmodell des Prozessmodells

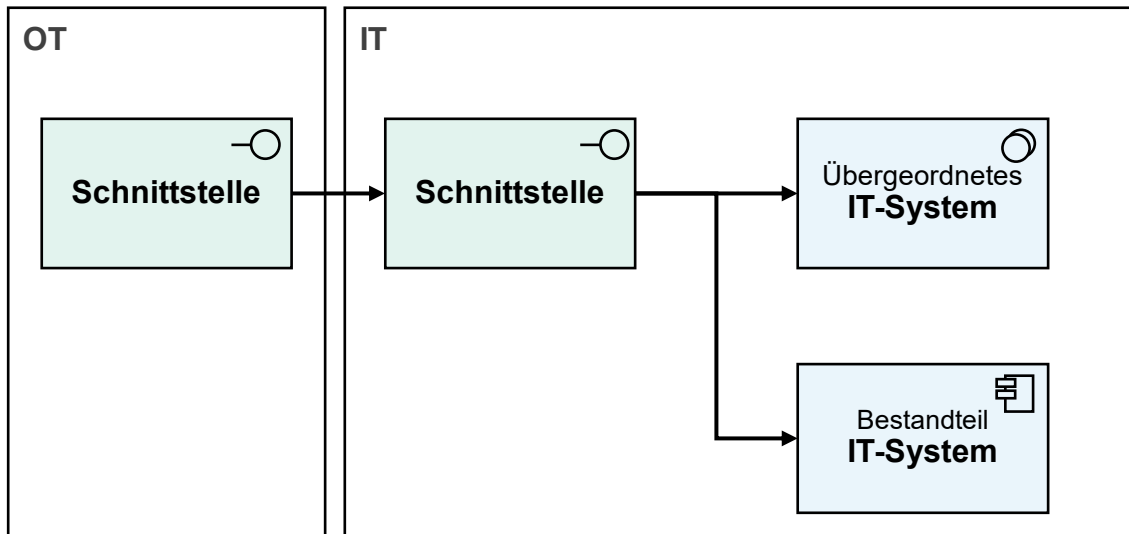


Bild A-14: Blueprint für das Partialmodell der Applikationsarchitektur

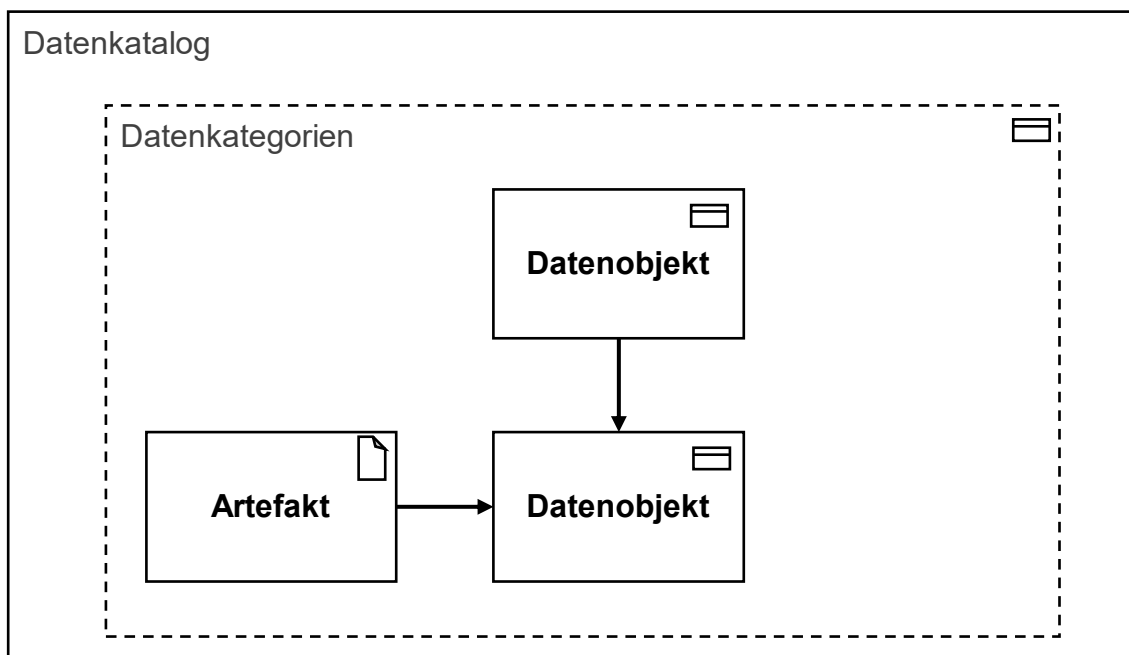


Bild A-15: Blueprint für das Partialmodell des Datenkatalogs

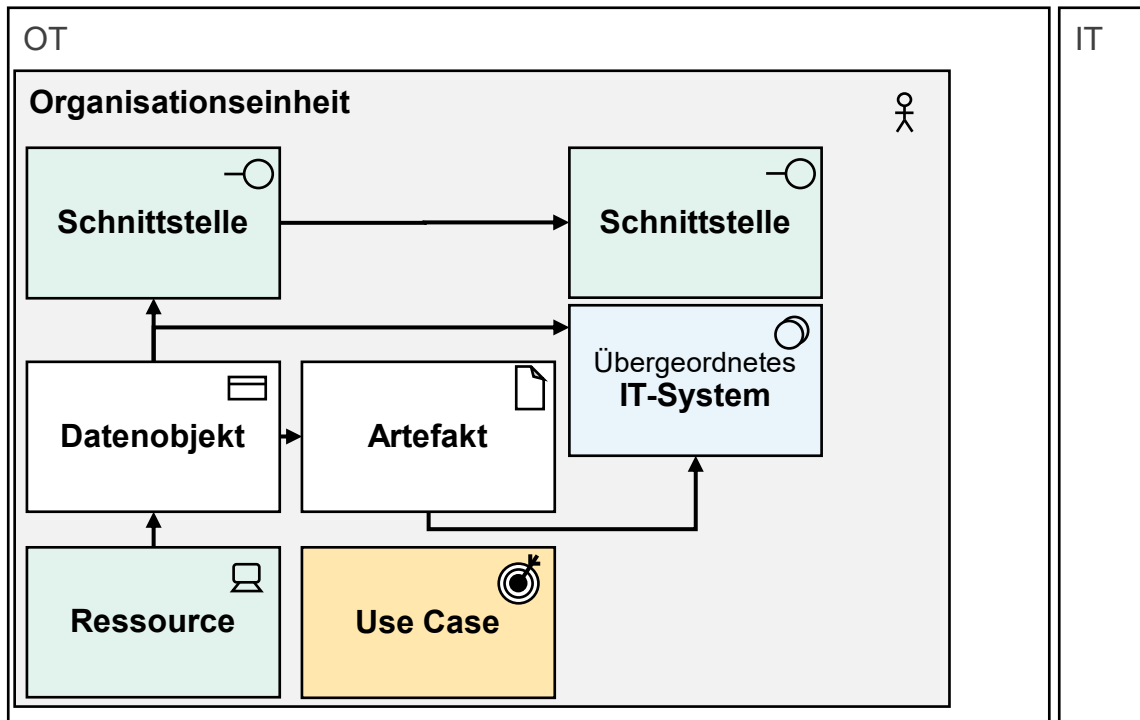


Bild A-16: Blueprint für das Partialmodell der technischen Architektur

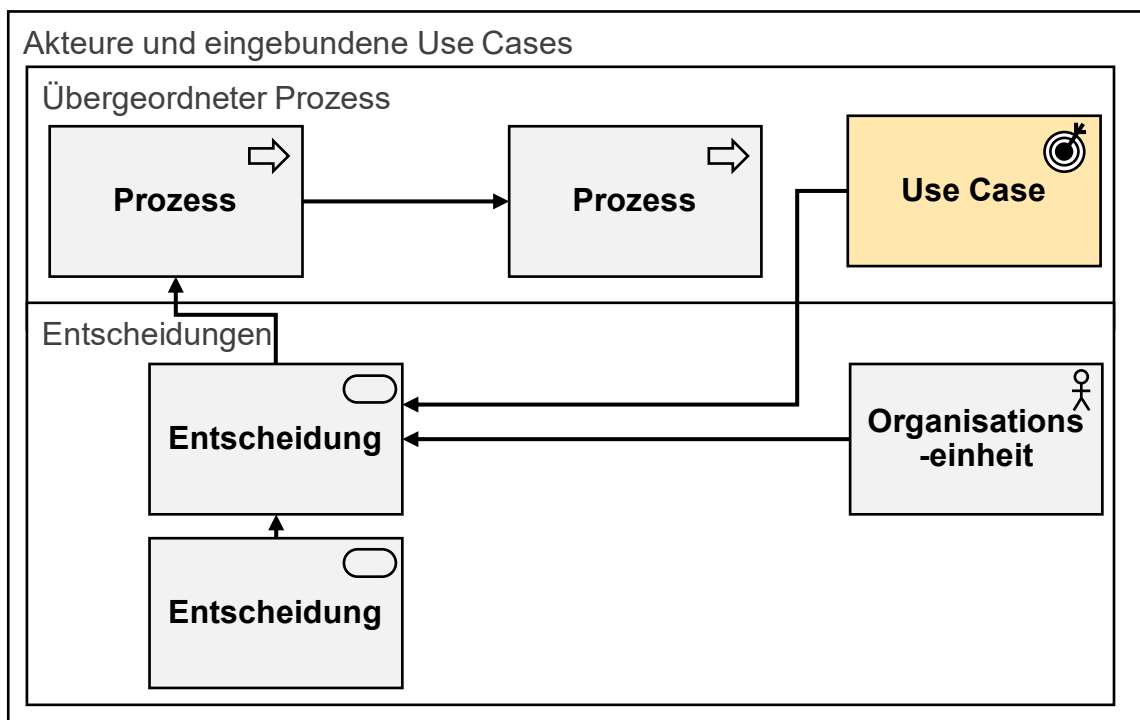


Bild A-17: Blueprint für das Partialmodell der Use Case Interaktion

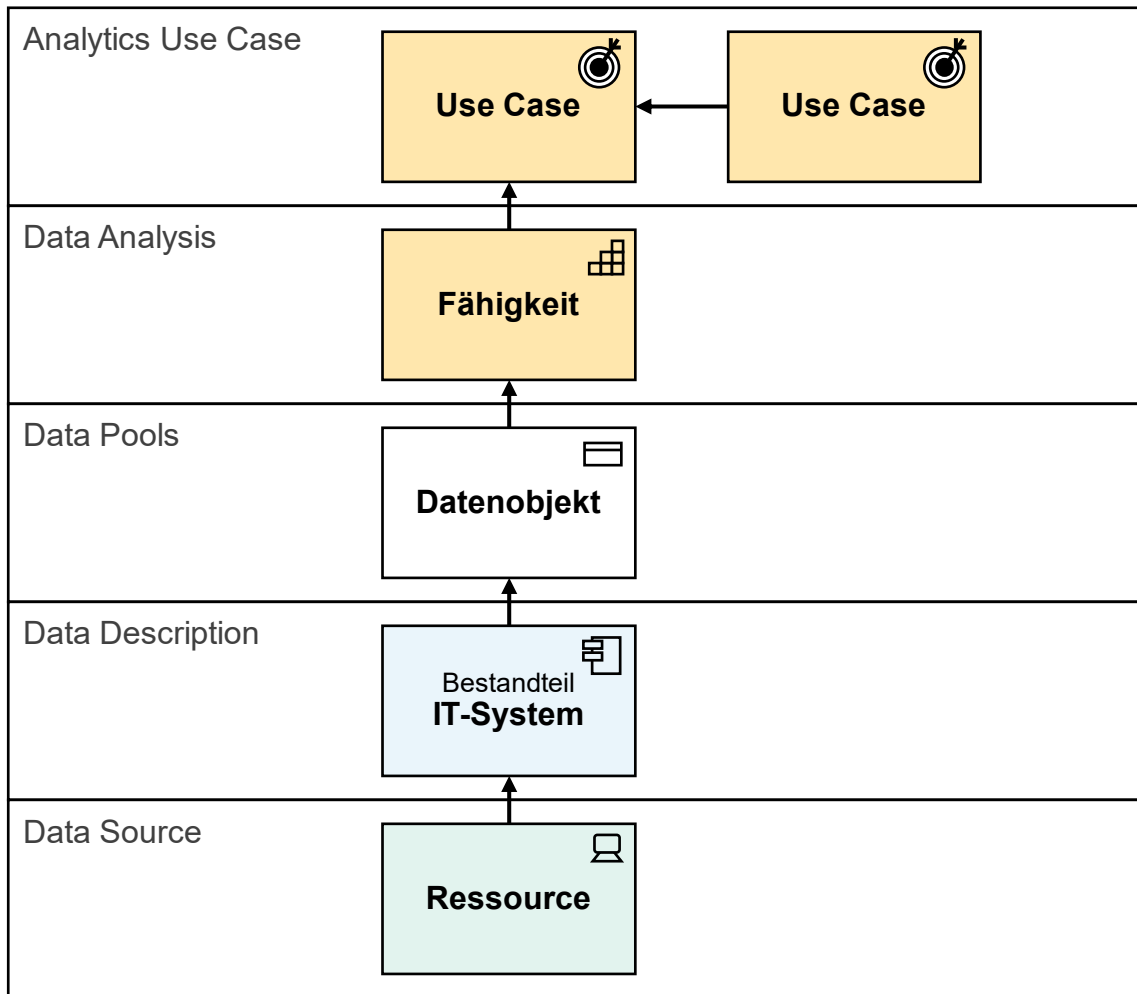


Bild A-18: Blueprint für das Partialmodell der Use Case Architektur

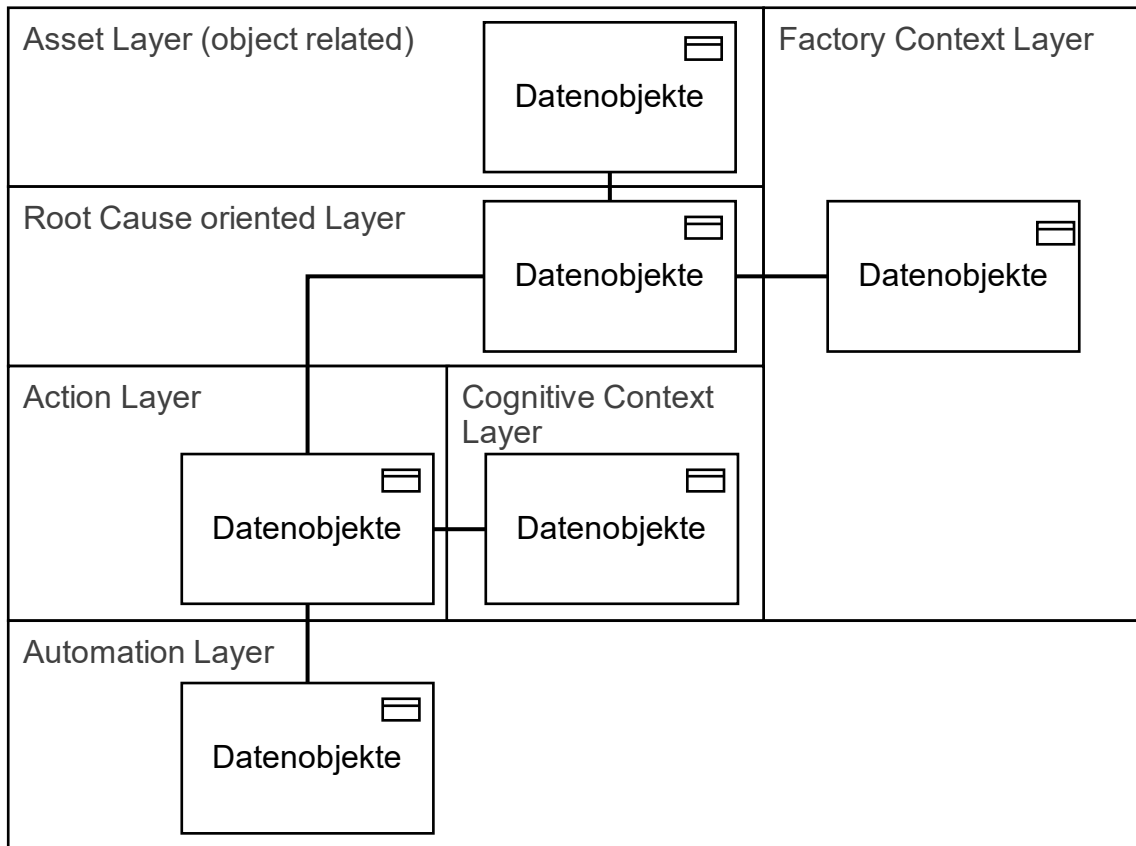


Bild A-19: Blueprint für das Partialmodell der Use Case Daten

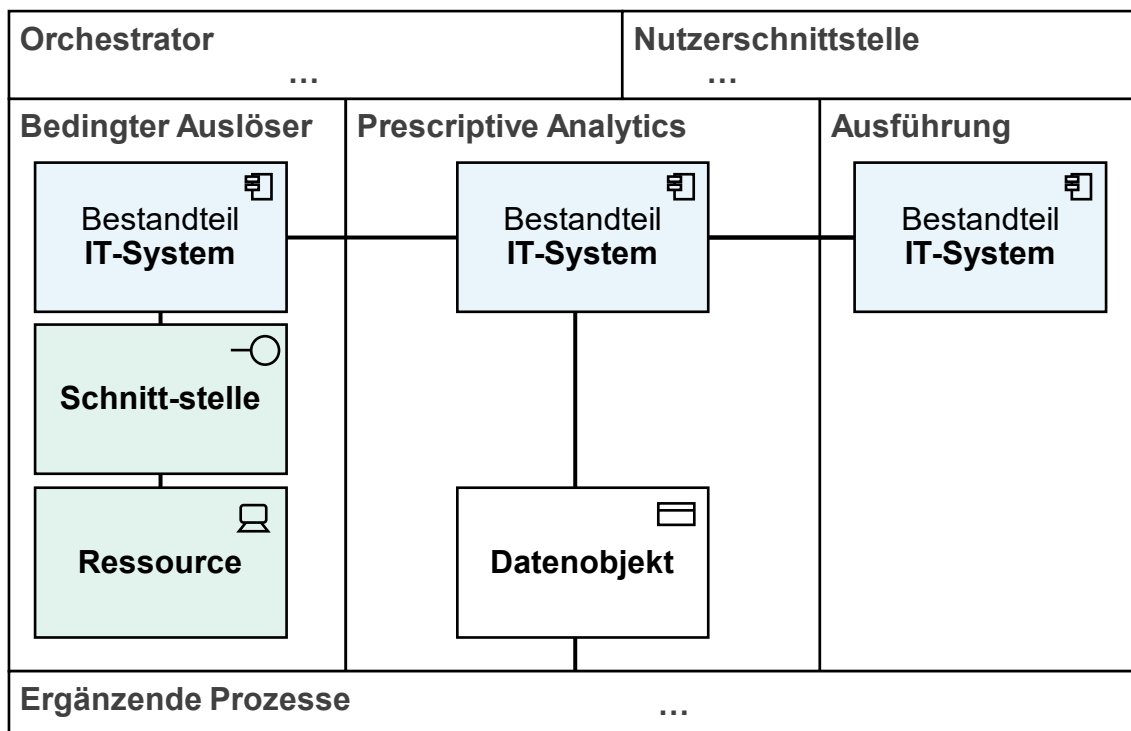


Bild A-20: Blueprint für das Partialmodell der Analytics Pipeline

## A2.9 Use Case Transformation Canvas mit Leitfragen

In Bild A-21 ist die Use Case Transformation Canvas mit Leitfragen abgebildet. Diese dient der Verwendung im Workshopformat oder als Handout.




Bild A-21: Use Case Transformation Canvas mit Leitfragen

## A2.10 Detaillierte Prescriptive Analytics Capability Map

Im Folgenden werden ergänzende Informationen zur Prescriptive Analytics Capability Map bereitgestellt. Die generische Capability Map berührt hier die Meta-Ebene der Ausarbeitung. Sie beschreibt einerseits welche Capabilities ein Unternehmen benötigt, um effektiv Advanced Analytics (und damit auch in besonderem Maße Prescriptive Analytics) Use Cases in einer vorliegenden Organisation zu entwickeln und einzuführen. Gleichzeitig beschreibt die Capability Map Capabilities, die durch die Anwendung der Schritte in der Ausarbeitung in einem Unternehmen direkt unterstützt und verbessert werden. Zuerst wird die allgemeine Verwendung einer Capability (vgl. Bild A-22) erläutert.

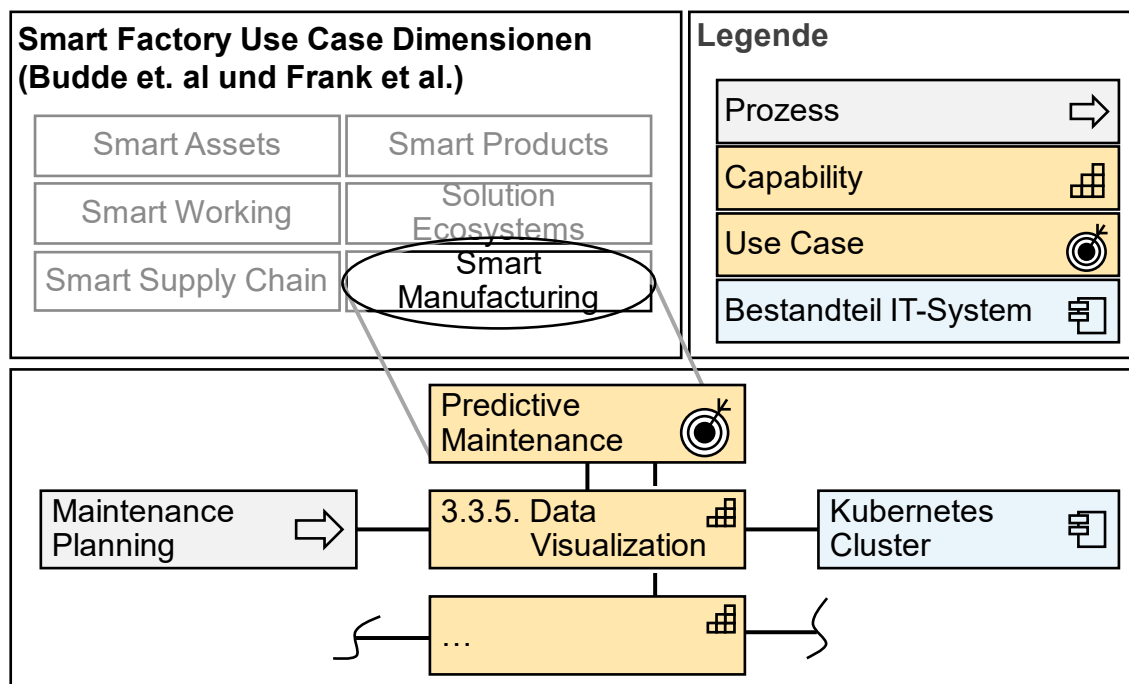
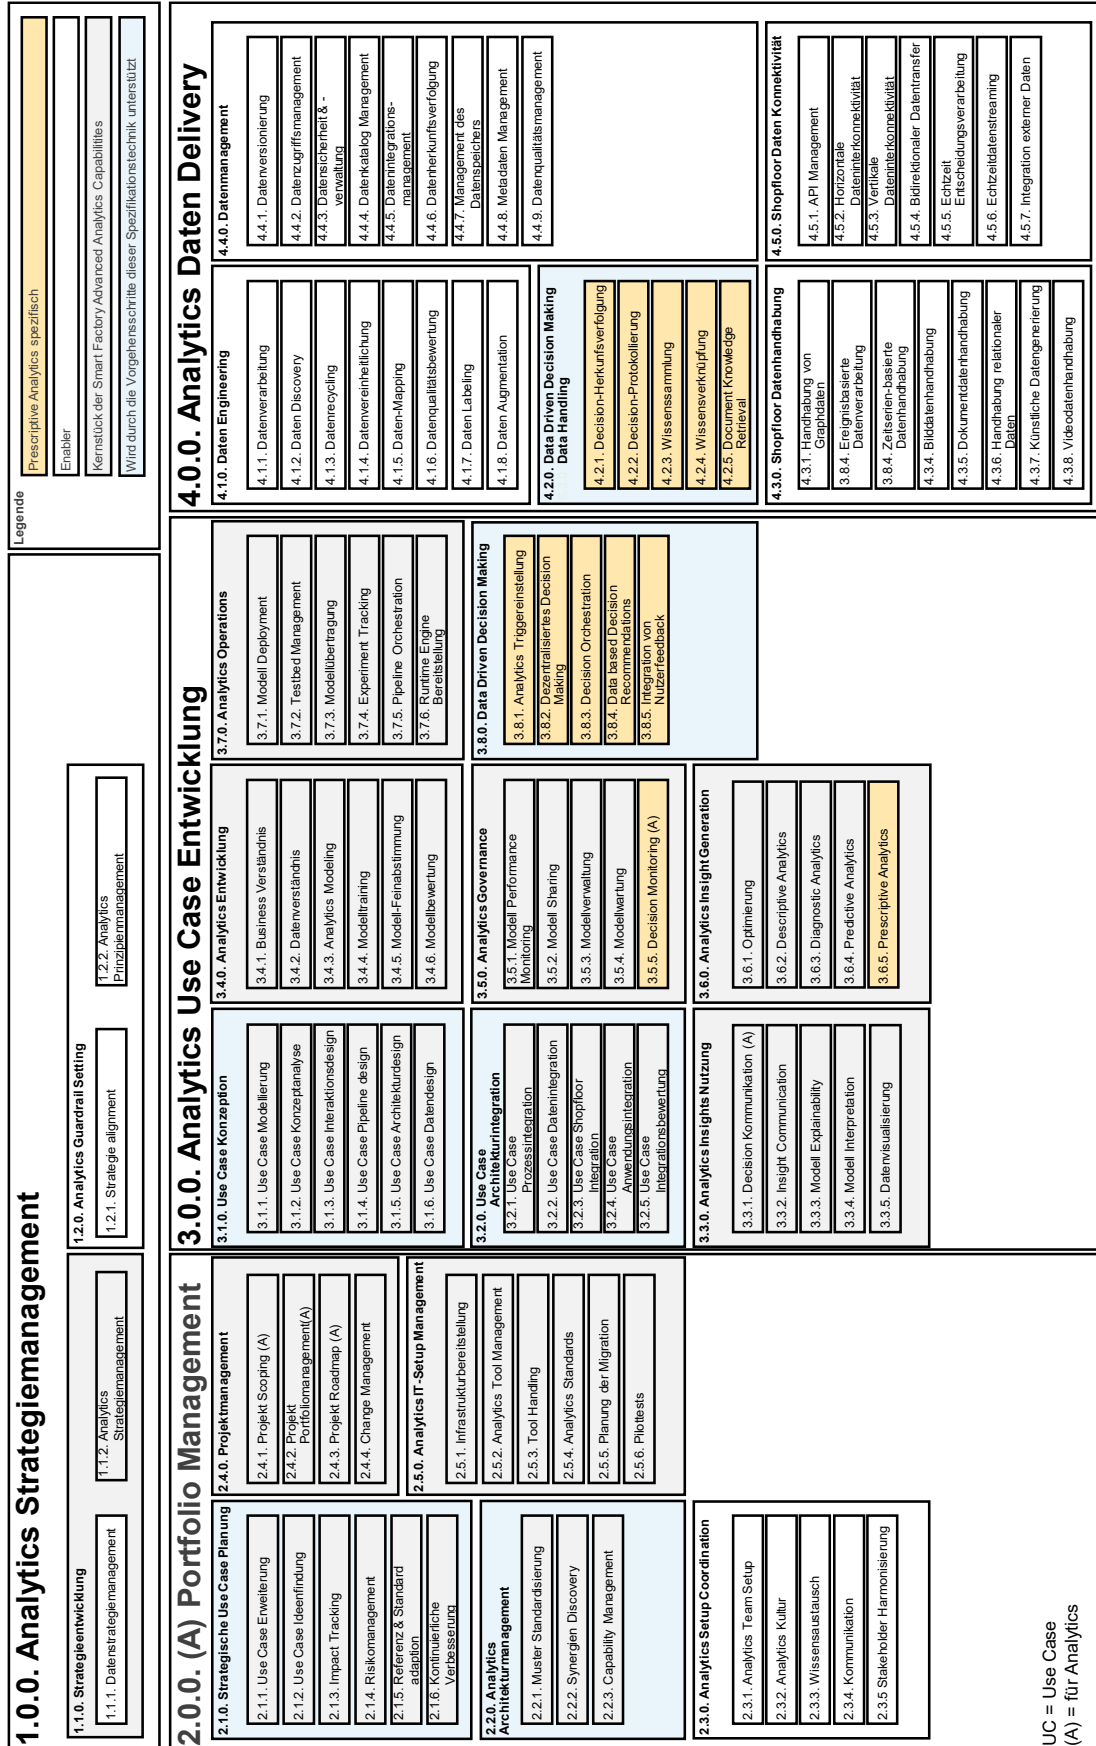


Bild A-22: Integration einer Capability in die Prozess- und IT-Applikationslandschaft aufbauend auf [FDA19, BHF+23]

Darauf aufbauend stellt Bild A-23 die detaillierte Version (Ebene drei) der Capability Map bereit. Die Legende teilt die Capabilities in jene ein, die Kern von Advanced Analytics, spezifisch für Aspekte des Prescriptive Analytics oder generelle Enabler Capabilities sind. Capabilities, welche durch den Scope dieser Ausarbeitung im gesonderten Maße unterstützt werden, sind zusätzlich gekennzeichnet.



Legende

Prescriptive Analytics spezifisch

Enabler

Kernstück der Smart Factory Advanced Analytics Capabilities

Wird durch die Vorgehensschritte dieser Spezifikationsmap unterstützt

UC = Use Case  
(A) = für Analytics

Bild A-23: Ebene drei der Prescriptive Analytics Capability Map für die Produktion

Ergänzend wird jede Capability mit einer Erläuterung in Tabelle A-8 ergänzt.

*Tabelle A-13: Kurze Erläuterung je Capability der Advanced Analytics Capability Map*

ID	Erläuterung
1.1.1.	<b>Datenstrategiemanagement</b> bezieht sich auf die Entwicklung und Überwachung eines umfassenden Plans für die Verwaltung von Datenbeständen zur Unterstützung fortschrittlicher Analysen in Smart Factories.
1.1.2.	<b>Analytics Strategiemanagement</b> bezieht sich auf die Erstellung und Ausführung eines strukturierten Plans für die Integration fortschrittlicher Analytics Use Cases in den Betrieb der Produktion. Diese Fähigkeit konzentriert sich auf die Definition eines zukünftigen Zustands, der mit den Geschäftszielen übereinstimmt.
1.2.3.	<b>Strategie Alignment</b> bedeutet, dass fortschrittliche Analyseinitiativen sich an vordefinierte Richtlinien und Grenzen halten, die mit den allgemeinen Geschäftszielen in der Produktion übereinstimmen.
1.2.4.	<b>Analytics Prinzipienmanagement</b> beinhaltet die Festlegung von Leitplanken, um Analyseprojekte auf die wichtigsten Ziele auszurichten und Abweichungen zu vermeiden, die die strategischen Ergebnisse beeinträchtigen könnten. So wird sichergestellt, dass die Analytics Bemühungen mit der langfristigen Vision und den Betriebsstandards der betrachteten Produktion übereinstimmen.
2.1.1.	<b>Use Case Erweiterung</b> bezieht sich auf den Prozess der Erweiterung erfolgreicher Analytics Use Cases auf eine höhere Stufe innerhalb des Grades der Unterstützung im Use Case.
2.1.2.	<b>Use Case Ideenfindung</b> bezieht sich auf den Prozess der Generierung und Identifizierung von Möglichkeiten, bei denen fortschrittliche Analytics Use Cases in Smart Factories eingesetzt werden kann. Dazu gehört das Brainstorming und Ideenfindung neuer Use Cases, die betriebliche Herausforderungen angehen oder die Effizienz und Produktivität verbessern.
2.1.3.	<b>Impact Tracking</b> bezieht sich auf die laufende Messung und Bewertung der Ergebnisse, die durch fortschrittliche Analytics Use Cases in Smart Factories erzielt werden. Diese Fähigkeit konzentriert sich auf die Überwachung der wichtigsten KPIs.
2.1.4.	<b>Risikomanagement</b> bezieht sich auf die Identifizierung, Bewertung und Minderung potenzieller Risiken im Zusammenhang mit der Implementierung fortschrittlicher Analytics Use Cases in Smart Factories.

2.1.5.	<b>Referenz- und Standard Adaption</b> bezieht sich auf den Prozess der Implementierung von innerbetrieblich und branchenübergreifenden anerkannten Rahmenwerken, Richtlinien und Best Practices bei der Entwicklung und Ausführung von Analytics Use Cases für Smart Factories.
2.1.6.	Die <b>kontinuierliche Use Case Verbesserung</b> bezieht sich auf den fortlaufenden Prozess der Verfeinerung und Optimierung von Analytics Use Cases. Sie trägt dazu bei, die Relevanz der Analytics Use Cases über einen längeren Zeitraum hinweg sicherzustellen.
2.2.1.	<b>Muster Standardisierung</b> bezieht sich auf die Erstellung und Anwendung konsistenter Frameworks und wiederholbarer Modelle für Analytics Use Cases in Smart Factories (vgl. [DAG13, S. 119]).
2.2.2.	<b>Synergy Discovery</b> bezieht sich auf die Identifizierung von Möglichkeiten, bei denen sich verschiedene Analytics Use Cases oder -Prozesse gegenseitig ergänzen können, um einen größeren Wert in Smart Factories zu schaffen.
2.2.3.	<b>Capability Management</b> bezieht sich auf den Prozess der Entwicklung und Aufrechterhaltung der erforderlichen Analytics Capabilities. Es umfasst die Bereitstellung einer Analytics Capability, um sicherzustellen, dass die Organisation fortschrittliche Analytics Lösungen effektiv implementieren und aufrechterhalten kann (vgl. [Togaf10]).
2.3.1.	<b>Analytics Team Setup</b> bezieht sich auf die Erhaltung und Einrichtung von Teams, welche für fortschrittliche Analytics in Smart Factories zuständig ist. Diese Fähigkeit umfasst die Definition von Rollen, den Erwerb der erforderlichen Capabilities und die Zuweisung von Ressourcen, um sicherzustellen, dass das Team Analytics Lösungen effektiv entwickeln und implementieren kann.
2.3.2.	<b>Analytics getriebene Kultur</b> legt den Schwerpunkt auf die Förderung des Einsatzes von Analytics Tools und Erkenntnissen bei allen Mitarbeitern und ermutigt zum kontinuierlichen Lernen.
2.3.3.	<b>Wissensaustausch</b> bezieht sich auf den systematischen Austausch von Informationen, Erkenntnissen und Fachwissen zwischen den Teammitgliedern, die in der Advanced Analytics Use Case Entwicklung für die Smart Factories beteiligt sind.
2.3.4.	<b>Kommunikation</b> bezieht sich auf den strukturierten Austausch von Informationen zwischen Analytics Teams, Stakeholdern und Fabrikpersonal, um Klarheit und Abstimmung in Analytics Use Cases für Smart Factories sicherzustellen.
2.3.5.	<b>Stakeholder Harmonisierung</b> bezieht sich auf den Prozess der Koordinierung und Harmonisierung der Ziele und Erwartungen aller Beteiligten, die an der Implementierung fortgeschrittener Analytics Use Cases in Smart Factories beteiligt sind.

2.4.1.	<b>Analytics Project Scoping</b> bezieht sich auf die Definition der Ziele, Ergebnisse, Ressourcen und Grenzen eines Analytics Use Case Umsetzungsprojektes in der Produktion.
2.4.2.	<b>Analytics Projekt Portfoliomanagement</b> bezieht sich auf die Überwachung und Koordination mehrerer Analytics Use Cases oder Projekte innerhalb der Produktion. Diese Fähigkeit konzentriert sich auf das Management der Auswahl, Priorisierung und Verfolgung von Analytics Umsetzungsaktivitäten.
2.4.3.	<b>Projekt Roadmapping</b> bezieht sich auf die Erstellung eines detaillierten Zeitplans und die Reihenfolge der Aktivitäten zur Implementierung fortgeschrittener Analytics Projekte in Smart Factories.
2.4.4.	<b>Change Management</b> konzentriert sich auf das Management der Auswirkungen von Veränderungen auf das Personal, die Arbeitsabläufe und die Systeme, um reibungslose Übergänge zu gewährleisten und Störungen zu minimieren.
2.5.1.	<b>Infrastrukturbereitstellung</b> bezieht sich auf die Bereitstellung und Verwaltung der notwendigen IT-Infrastruktur, wie Server, Netzwerke und Cloud-Ressourcen, zur Unterstützung von fortgeschrittenen Analytics Use Cases in Smart Factories.
2.5.2.	<b>Analytics Tool Management</b> bezieht sich auf die Auswahl, Bereitstellung und Wartung der Software und Tools, die für fortgeschrittene Analytics in Smart Factories verwendet werden.
2.5.3.	<b>Tool Handling</b> bezieht sich auf den effektiven Betrieb und die Verwaltung von Analytics Software für Smart Factories.
2.5.4.	<b>Analytics Standards</b> bezieht sich auf die Etablierung und Durchsetzung konsistenter Richtlinien, Praktiken und Protokolle für die Implementierung von Analytics Lösungen in Smart Factories. Diese Fähigkeit stellt sicher, dass Analytics Prozesse, Datenverarbeitung und Tool-Nutzung festgelegten Normen folgen, um Qualität, Interoperabilität und Compliance zu verbessern. Sie hilft, Konsistenz und Zuverlässigkeit in allen Analytics Initiativen zu gewährleisten.
2.5.5.	<b>Planung der Migration</b> bezieht sich auf die Strategie und Durchführung des Übergangs von Daten, Systemen oder Analytics Tools auf neue Plattformen oder von der Entwicklungsumgebung in die Produktivumgebung in Smart Factories.
2.5.6.	<b>Pilottests</b> bezieht sich auf die Testimplementierung von fortgeschrittenen Analytics Use Cases in kleinem Maßstab innerhalb von Smart Factories, um ihre Wirksamkeit und Machbarkeit zu bewerten.
3.1.1.	<b>Use Case Modellierung</b> bezieht sich auf den Prozess der Gestaltung und modellbasierten Abbildung spezifischer Analytics Use Cases sowie deren Umfeld in Smart Factories.

3.1.2.	<b>Use Case Konzeptanalyse</b> bezieht sich auf den Prozess der Bewertung und Analyse vorgeschlagener Analytics Ideen innerhalb von Smart Factories. Dies umfasst das Aufdecken von Synergien und Schnittstellen.
3.1.3.	<b>Use Case Interaktionsdesign</b> bezieht sich auf den Prozess der Konzeption, wie Benutzer mit Analytics Lösungen innerhalb von Smart Factories interagieren.
3.1.4.	<b>Use Case Pipeline Design</b> bezieht sich auf die Konzeption einer strukturierten Pipeline für spezifische Analytics Use Cases zur Implementierung in Smart Factories.
3.1.5.	<b>Use Case Architekturdesign</b> bezieht sich auf die Konzeption einer Use Case Architektur für Advanced Analytics Use Cases in der Produktion.
3.1.6.	<b>Use Case Datendesign</b> bezieht sich auf den Prozess der Konzeption der Datenarchitektur, die zur Implementierung von Analytics Use Cases in Smart Factories erforderlich sind.
3.2.1.	<b>Use Case Prozessintegration</b> bezieht sich auf die nahtlose Einbettung fortgeschrittener Analytics Lösungen in die bestehenden operativen Arbeitsabläufe und Prozesse von Smart Factories.
3.2.2.	<b>Use Case Datenintegration</b> bezieht sich auf die Konsolidierung und Harmonisierung von Daten aus verschiedenen Quellen zur Unterstützung spezifischer Analytics Use Cases in Smart Factories.
3.2.3.	<b>Use Case Shopfloor Integration</b> bezieht sich auf die nahtlose Einbindung fortgeschrittener Analytics Lösungen in die operativen Arbeitsabläufe und Systeme auf dem Produktionsboden von Smart Factories (technische Architektur).
3.2.4.	<b>Use Case Anwendungsintegration</b> bezieht sich auf die nahtlose Einbindung fortgeschrittener Analytics Use Cases in die bestehenden Softwaresysteme (Applikationsarchitektur) innerhalb von Smart Factories.
3.2.5.	<b>Use Case Integrationsbewertung</b> bezieht sich auf die Bewertung der Effektivität, mit der fortgeschrittene Analytics Use Cases in die bestehenden Systeme und Arbeitsabläufe von Smart Factories integriert werden.
3.3.1.	<b>Decision Kommunikation</b> bezieht sich auf die klare und effektive Verbreitung von datengesteuerten Entscheidungen an Stakeholder innerhalb von Smart Factories.
3.3.2.	<b>Insight Communication</b> bezieht sich auf den effektiven Austausch und die Präsentation von datengesteuerten Erkenntnissen, die aus fortgeschrittenen Analytics gewonnen werden, an relevante Stakeholder innerhalb von Smart Factories.

3.3.3.	<b>Model Explainability</b> bezieht sich auf den Prozess, fortgeschrittene Analytics Modelle für Benutzer innerhalb von Smart Factories verständlich und transparent zu machen.
3.3.4.	<b>Model Interpretation</b> bezieht sich auf den Prozess der Analyse und des Verständnisses, wie fortgeschrittene Analytics Modelle ihre Vorhersagen oder Entscheidungen innerhalb von Smart Factories generieren.
3.3.5.	<b>Datenvisualisierung</b> bezieht sich auf die Fähigkeit, grafische Darstellung von Daten und Analytics Erkenntnissen bereitzustellen, um das Verständnis und die Entscheidungsfindung innerhalb von Smart Factories zu erleichtern.
3.4.1.	<b>Business Verständnis</b> bezieht sich auf den Prozess, die betrieblichen Ziele, Herausforderungen und Anforderungen von Smart Factories umfassend zu identifizieren und zu analysieren, um die Implikationen für die Entwicklung fortgeschrittener Analytics Use Cases abzuleiten (vgl. [She00]).
3.4.2.	<b>Datenverständnis</b> bezieht sich auf den Prozess der Erkundung und Analyse (Verständnisgewinn) von Datenquellen innerhalb von Smart Factories, um relevante Informationen zu identifizieren und die Datenqualität für fortgeschrittene Analytics Projekte zu bewerten (vgl. [She00]).
3.4.3.	<b>Analytics Modeling</b> bezieht sich auf die Erstellung und Entwicklung mathematischer und statistischer Modelle (Analytics Lösungen) zur Analyse von Daten und zur Generierung von Erkenntnissen für den Betrieb von Smart Factories (vgl. [She00]).
3.4.4.	<b>Modeltraining</b> bezieht sich auf den Prozess, fortgeschrittenen Analytics Modellen zu trainieren.
3.4.5.	<b>Modell-Feintuning</b> bezieht sich auf den Prozess der Anpassung und Optimierung fortgeschrittener Analytics Modelle, um ihre Genauigkeit und Leistung innerhalb der Betriebsabläufe von Smart Factories zu verbessern.
3.4.6.	<b>Modellbewertung</b> bezieht sich auf die systematische Bewertung fortgeschrittener Analytics Modelle, um ihre Wirksamkeit und Genauigkeit innerhalb der Betriebsabläufe von Smart Factories zu bestimmen.
3.5.1.	<b>Model Performance Monitoring</b> bezieht sich auf die kontinuierliche Überwachung und Bewertung der Analytics Modelle, um ihre Genauigkeit und Effektivität innerhalb der Betriebsabläufe von Smart Factories sicherzustellen.
3.5.2.	<b>Model Sharing</b> bezieht sich auf den Prozess der Verteilung und Zugänglichmachung von fortgeschrittenen Analytics Modellen für verschiedene Teams und Stakeholder innerhalb von Smart Factories.

3.5.3.	<b>Modellverwaltung</b> bezieht sich auf den Prozess der Verwaltung (Rahmen aus Richtlinien, Standards und Verfahren, die die Entwicklung, Bereitstellung) von Analytics Modellen in Smart Factories überwachen.
3.5.4.	<b>Modellwartung</b> bezieht sich auf die fortlaufenden Aktivitäten, die erforderlich sind, um Analytics Modelle genau, aktuell und effektiv innerhalb der Betriebsabläufe von Smart Factories zu halten.
3.5.5.	<b>Decision Monitoring</b> bezieht sich auf den Prozess der Nachverfolgung und Bewertung der Effektivität von Entscheidungen, die mithilfe fortgeschrittener Analytics in Smart Factories getroffen wurden.
3.6.1.	<b>Optimierung</b> bezieht sich auf den Prozess der Nutzung fortgeschrittener Analytics, um die Betriebsabläufe innerhalb von Smart Factories zu verbessern und zu optimieren.
3.6.2.	<b>Descriptive Analytics</b> bezieht sich auf den Prozess der Analyse historischer Produktionsdaten, um die vergangene Leistung und betriebliche Trends innerhalb von Smart Factories bereitzustellen (vgl. [SSK+14-ol]).
3.6.3.	<b>Diagnostic Analytics</b> bezieht sich auf den Prozess der Untersuchung von Produktionsdaten, um die Ursachen spezifischer Probleme oder Ereignisse innerhalb von Smart Factories zu ermitteln (vgl. [SSK+14-ol]).
3.6.4.	<b>Predictive Analytics</b> bezieht sich auf den Prozess der Nutzung historischer und Echtzeit-Daten, um zukünftige Ereignisse oder Trends innerhalb von Smart Factories vorherzusagen (vgl. [SSK+14-ol]).
3.6.5.	<b>Prescriptive Analytics</b> bezieht sich auf den Prozess der Nutzung von Datenanalysen, um spezifische Maßnahmen zur Optimierung von Ergebnissen innerhalb von Smart Factories zu empfehlen (vgl. [SSK+14-ol]).
3.7.1.	<b>Modell Deployment</b> bezieht sich auf den Prozess der Bereitstellung fortgeschrittener Analytics Modelle in den Betriebssystemen der Smart Factories.
3.7.2.	<b>Testbed Management</b> bezieht sich auf die Einrichtung und Wartung kontrollierter Umgebungen zur Entwicklung, Prüfung und Validierung von Advanced Analytics Lösungen innerhalb von Smart Factories.
3.7.3.	<b>Modellübertragung</b> bezieht sich auf den Prozess des Übertrags fortgeschrittener Analytics Modelle von einem Bezugssystem in ein anderes.
3.7.4.	<b>Experiment Tracking</b> bezieht sich auf die systematische Protokollierung und Überwachung von Machine-Learning-Experimenten innerhalb von Smart Factories.
3.7.5.	<b>Pipeline Orchestration</b> bezieht sich auf das automatisierte Management und die Koordination von Datenverarbeitungs- und Analytics-Workflows innerhalb von Smart Factories.

3.7.6.	<b>Runtime Engine Bereitstellung</b> bezieht sich auf den Prozess der Installation und Konfiguration der Ausführungsumgebung, die fortgeschrittene Analytics Modelle innerhalb von Smart Factories betreibt.
3.8.1.	<b>Analytics Triggereinstellung</b> bezieht sich auf die Konfiguration spezifischer Bedingungen oder Schwellenwerte, die automatisch Analytics Prozesse oder Entscheidungsaktionen innerhalb von Smart Factories aktivieren.
3.8.2.	<b>Dezentralisiertes Decision Making</b> bezieht sich auf die Verteilung der Entscheidungsbefugnis auf verschiedene Teams und Ebenen innerhalb von Smart Factories, unterstützt durch fortgeschrittene Analytics.
3.8.3.	<b>Decision Orchestration</b> bezieht sich auf das koordinierte Management und die Ausführung datengesteuerter Entscheidungen über verschiedene Systeme und Prozesse hinweg innerhalb von Smart Factories.
3.8.4.	<b>Data-based Decision Recommendations</b> bezieht sich auf die Generierung umsetzbarer Vorschläge, die aus der Datenanalyse abgeleitet werden, um Entscheidungsprozesse innerhalb von Smart Factories zu unterstützen.
3.8.5.	<b>Integration von Nutzerfeedback</b> bezieht sich auf den Prozess der Einbindung von Erkenntnissen und Rückmeldungen von Bedienern und anderen Stakeholdern in die Analytics Systeme von Smart Factories.
4.1.1.	<b>Datenverarbeitung</b> bezieht sich auf die Sammlung, Transformation und Vorbereitung von Rohdaten in ein nutzbares Format für fortgeschrittene Analytics in Smart Factories.
4.1.2.	<b>Daten Discovery</b> bezieht sich auf den Prozess der Identifizierung, Erforschung und des Verstehens von Datenquellen innerhalb von Smart Factories, um wertvolle Erkenntnisse für fortgeschrittene Analytics zu gewinnen.
4.1.3.	<b>Datenrecycling</b> bezieht sich auf die Praxis, vorhandene Daten über mehrere Analytics Use Cases hinweg innerhalb von Smart Factories zu nutzen, um deren Wert zu maximieren.
4.1.4.	<b>Datenvereinheitlichung</b> bezieht sich auf den Prozess der Standardisierung und Angleichung von Daten aus mehreren Quellen, um Konsistenz und Kompatibilität für fortgeschrittene Analytics in Smart Factories sicherzustellen.
4.1.5.	<b>Daten-Mapping</b> bezieht sich auf den Prozess, bei dem Datenfelder aus verschiedenen Quellen in eine einheitliche Struktur oder ein Modell innerhalb von Smart Factories überführt werden.
4.1.6.	<b>Datenqualitätsbewertung</b> bezieht sich auf die Bewertung von Daten, um sicherzustellen, dass sie für fortgeschrittene Analytics in Smart Factories genau, vollständig, konsistent und zuverlässig sind.

4.1.7.	<b>Daten Labeling</b> bezieht sich auf den Prozess der Zuweisung aussagekräftiger Tags oder Annotationen zu Daten, um es fortgeschrittenen Analytics Modellen in Smart Factories zu erleichtern, die Informationen zu interpretieren und zu verarbeiten.
4.1.8.	<b>Daten Augmentation</b> bezieht sich auf die Technik, zusätzliche, modifizierte Versionen bestehender Daten zu erstellen, um die Vielfalt und das Volumen der für fortgeschrittene Analytics in Smart Factories verfügbaren Daten zu erhöhen.
4.2.1.	<b>Decision-Herkunftsverfolgung</b> bezieht sich auf die Nachverfolgung und Dokumentation der Daten, Modelle und Prozesse, die zu bestimmten Entscheidungen in fortgeschrittenen Analytics für Smart Factories führen.
4.2.2.	<b>Decision-Protokollierung</b> bezieht sich auf die systematische Aufzeichnung von Entscheidungen, die auf fortgeschrittenen Analytics in Smart Factories basieren.
4.2.3.	<b>Wissenssammlung</b> bezieht sich auf den Prozess der Sammlung und Organisation relevanter Informationen, Daten und Erkenntnisse zur Unterstützung datengestützter Entscheidungsprozesse in Smart Factories.
4.2.4.	<b>Wissensverknüpfung</b> bezieht sich auf die Verknüpfung und Integration von Daten, Erkenntnissen und Informationen über verschiedene Systeme und Prozesse hinweg in Smart Factories.
4.2.5.	<b>Document Knowledge Retrieval</b> bezieht sich auf den Prozess des Zugriffs auf und der Extraktion relevanter Informationen aus Dokumenten und Aufzeichnungen zur Unterstützung datengestützter Entscheidungsprozesse in Smart Factories.
4.3.1.	<b>Handhabung von Graphdaten</b> bezieht sich auf das Management und die Verarbeitung von Daten, die Beziehungen zwischen Entitäten in einer Graphstruktur innerhalb von Smart Factories darstellen.
4.3.2.	<b>Ereignisbasierte Datenverarbeitung</b> bezieht sich auf die Verarbeitung und Verwaltung von Daten, die durch spezifische Ereignisse oder Trigger auf dem Shopfloor in Smart Factories generiert werden.
4.3.3.	<b>Zeitreihen-basierte Datenhandhabung</b> bezieht sich auf das Management und die Analyse von Daten, die in chronologischer Reihenfolge aus den Shopfloor-Betriebsabläufen in Smart Factories erfasst und organisiert werden.
4.3.4.	<b>Bilddatenhandhabung</b> bezieht sich auf das Management, die Verarbeitung und Analyse von visuellen Daten, wie z. B. Bildern, die von Kameras oder Sensoren innerhalb von Smart Factories erfasst werden.
4.3.5.	<b>Dokumentdatenhandhabung</b> bezieht sich auf das Management, die Verarbeitung und Analyse von textbasierten und strukturierten Daten

	aus Dokumenten, die in den Betriebsabläufen von Smart Factories verwendet werden.
4.3.6.	<b>Handhabung relationaler Daten</b> bezieht sich auf das Management und die Verarbeitung von Daten, die in Tabellen organisiert und über definierte Beziehungen miteinander verbunden sind innerhalb von Smart Factories.
4.3.7.	<b>Künstliche Datengenerierung</b> bezieht sich auf die Erstellung, Verwaltung und Analyse von künstlich generierten Daten, die reale Daten in Smart Factories nachahmen.
4.3.8.	<b>Videodatenhandhabung</b> bezieht sich auf den Prozess der Erfassung, Verarbeitung und Analyse von Videodaten aus dem Shopfloor in Smart Factories.
4.4.1.	<b>Datenversionierung</b> bezieht sich auf den systematischen Prozess der Verwaltung und Verfolgung mehrerer Versionen von Datensätzen im Laufe der Zeit in fortgeschrittenen Analytics für Smart Factories.
4.4.2.	<b>Datenzugriffmanagement</b> bezieht sich auf die Kontrolle und Regulierung, wer auf Daten innerhalb der Analytics Systeme von Smart Factories zugreifen, diese verwenden und ändern kann. Diese Fähigkeit stellt sicher, dass nur autorisierte Personen auf spezifische Datensätze zugreifen, um Sicherheit, Datenschutz und Compliance zu gewährleisten. Sie schützt sensible Informationen und stellt sicher, dass Daten angemessen und effizient innerhalb der Organisation genutzt werden.
4.4.3.	<b>Datensicherheit und -verwaltung</b> bezieht sich auf die Richtlinien und Maßnahmen, die zum Schutz von Daten und zur Sicherstellung ihrer ordnungsgemäßen Verwaltung innerhalb der Analytics Systeme von Smart Factories implementiert werden.
4.4.4.	<b>Datenkatalog Management</b> bezieht sich auf die Organisation und Pflege eines zentralisierten Verzeichnisses, das detaillierte Informationen über die verfügbaren Daten (Semantik und Ontology) innerhalb der Analytics Systeme von Smart Factories bereitstellt.
4.4.5.	<b>Datenintegrationsmanagement</b> bezieht sich auf den Prozess der Kombination von Daten aus verschiedenen Quellen in einem einheitlichen System für fortgeschrittene Analytics in Smart Factories.
4.4.6.	<b>Datenherkunftsverfolgung</b> bezieht sich auf die Nachverfolgung und Dokumentation des Ursprungs, der Bewegung und der Transformationen von Daten, während diese durch verschiedene Systeme in den Analytics Prozessen von Smart Factories fließen.
4.4.7.	<b>Datenspeichermanagement</b> bezieht sich auf die Organisation, Pflege und Optimierung von Datenspeichersystemen, die für fortgeschrittene Analytics in Smart Factories verwendet werden.

4.4.8.	<b>Metadaten Management</b> bezieht sich auf den Prozess der Organisation und Pflege von Informationen über Daten, wie deren Quelle, Struktur und Nutzung, innerhalb der Analytics Systeme von Smart Factories.
4.4.9.	<b>Datenqualitätsmanagement</b> bezieht sich auf den systematischen Prozess zur Sicherstellung, dass die für fortgeschrittene Analytics in Smart Factories verwendeten Daten genau, konsistent und zuverlässig sind.
4.5.1.	<b>API Management</b> bezieht sich auf den Prozess der Überwachung und Kontrolle der Nutzung von Application Programming Interfaces (APIs), die den Datenaustausch zwischen Systemen in Smart Factories ermöglichen.
4.5.2.	<b>Horizontale Dateninterkonnektivität</b> bezieht sich auf den nahtlosen Datenaustausch zwischen verschiedenen Systemen, Maschinen und Prozessen, die auf derselben Ebene innerhalb von Smart Factories arbeiten.
4.5.3.	<b>Vertikale Dateninterkonnektivität</b> bezieht sich auf die Integration und den nahtlosen Datenfluss zwischen verschiedenen hierarchischen Ebenen innerhalb der Produktion, von Shopfloor-Maschinen bis hin zu höherstufigen Managementsystemen.
4.5.4.	<b>Bidirektionaler Datentransfer</b> bezieht sich auf die Fähigkeit, Daten zwischen Systemen, Maschinen und Analytics Plattformen in der Produktion zu senden und zu empfangen.
4.5.5.	<b>Echtzeit Entscheidungsverarbeitung</b> bezieht sich auf die Fähigkeit, sofortige, datengestützte Entscheidungen auf Grundlage von Echtzeit-Daten aus den Shopfloor-Betriebsabläufen in Smart Factories zu treffen.
4.5.6.	<b>Echtzeitdatenstreaming</b> bezieht sich auf den kontinuierlichen Fluss von Daten aus den Systemen und Sensoren auf dem Shopfloor zu den Analytics Plattformen ohne Verzögerung in Smart Factories.
4.5.7.	<b>Integration externer Daten</b> bezieht sich auf den Prozess der Einbindung von Daten aus externen Quellen, wie Lieferanten, Kunden oder Marktdaten, in die Analytics Systeme der Produktion.

## A2.11 Beispielhafte Analysefragen für das Modell

Das Bild A-24 gibt einen Überblick zu möglichen Analysefragen des ArchiMate Modells.

Analyse von Synergien- und Schnittstellen			
Nutzung der Architekturmodells als Informationsbasis			
Komplexitätsanalysen	Konformitätsanalysen	Kostenanalysen	Nutzenanalysen
Werden Akteure in Ihrem Arbeitsprozess von mehreren Use Cases beeinflusst?			
Wie zentral ist ein Objekt über mehrere Use Cases hinweg? (Basierend auf der Anzahl seiner Verbindungen in allen)			
Welche Use Cases beanspruchen ähnliche Ressourcen (z. B. Mitarbeiter)?			
Sind alle Datenobjekte mit Datenbanken verbunden? (generell für Konzepte)			
Welche Use Cases verfolgen ähnliche oder sich überschneidende Ziele?			
Gibt es Gemeinsamkeiten wie ein Objekt in verschiedenen Use Cases verwendet wird? (Musterident.)			
Direkte Analyse des Architekturmodells			
Abhängigkeitsanalysen	Abdeckungsanalysen	Schnittstellenanalysen	Heterogenitätsanalysen
Wird ein spezifisches Modellierungsobjekt in mehreren Use Cases verwendet?			
Sind alle Bestandteile vollständig verbunden? Welche Verbindungen fehlen?			
Sind alle Projekte mit den Zielen verbunden, die sie unterstützen sollen?			
Wie aktuell ist das Modell?			
Formulierung der Capabilities nach Guidelines?			
Gibt es funktionale Überschneidungen in den Anwendungslogiken mehrerer Use Cases?			

Bild A-24: Leitfragen zur Modellanalyse für die ArchiMate Spezialisierung

## A3 Forschungsdesign der Spezifikationstechnik

Im Folgenden werden Ergänzungen zum Forschungsdesign beschrieben. Diese Ergänzungen dienen lediglich der weiteren Ausführung teilweise angeschnittener Aspekte.

### A3.1 Herleitung des übergeordneten Vorgehensmodells

In Kapitel 2.5.6 wurde bereits kurz auf verschiedene Data Science Entwicklungsvorgehen eingegangen. MARTINEZ ET AL. haben in einer Studie zu verschiedenen Data Science Vorgehensmodellen deren Eignung in Bezug auf managementrelevante Aspekte untersucht (**Team-, Projekt- und Daten-/Informationsmanagement**). Darauf basierend fordern sie ein Update für CRISP-DM. Die Autoren bemängeln unter anderem eine fehlende Adressierung von team- und projektmanagementbezogenen Herausforderungen. Es gibt viele weitere weniger etablierte Ansätze (siehe Bewertung Tabelle A-14) mit verschiedenen Schwerpunkten. In Bezug auf deren Integrität zu team-, projekt-, daten- und informationsrelatierten Challenges schneidet das RAMSYS Modell am besten ab (siehe Tabelle A-14). Die Einträge sind nach ihrer gemittelten Bewertung absteigend sortiert. Eine Herleitung der Bewertung kann [MVO21] entnommen werden.

*Tabelle A-14: Überblick über die Fokus Punkte verschiedener Vorgehensmodelle im Kontext der Data Science Use Case Entwicklung in Anlehnung an [MVO21]*

Vorgehensmodell	Projekt Management		Team Management		Daten- & Informationsmanagement	
	Bewertung	Integrität	Bewertung	Integrität	Bewertung	Integrität
RAMSYS [MJ01]	67%	<input type="checkbox"/>	78%	<input type="checkbox"/>	57%	<input type="checkbox"/>
Microsoft TDSP [Mic17]	81%	<input type="checkbox"/>	61%	<input type="checkbox"/>	52%	<input type="checkbox"/>
Agile Delivery Framework [LC16]	81%	<input type="checkbox"/>	39%	<input type="checkbox"/>	52%	<input type="checkbox"/>
Domino DS Lifecycle [Nic18]	57%	<input type="checkbox"/>	61%	<input type="checkbox"/>	52%	<input type="checkbox"/>
EMC Data Analytics Lifecycle [Die16]	71%	<input type="checkbox"/>	56%	<input type="checkbox"/>	38%	<input type="checkbox"/>
Agile Data Science Lifecycle [Jur17]	48%	<input type="checkbox"/>	72%	<input type="checkbox"/>	38%	<input type="checkbox"/>
Systematic Research on Big Data [DCC+15, Col12]	67%	<input type="checkbox"/>	56%	<input type="checkbox"/>	33%	<input type="checkbox"/>
Big Data Management Canvas [Kau19]	76%	<input type="checkbox"/>	28%	<input type="checkbox"/>	48%	<input type="checkbox"/>
Toward data mining engineering[MSM+08]	71%	<input type="checkbox"/>	22%	<input type="checkbox"/>	57%	<input type="checkbox"/>
Big Data Managing Framework [DB15]	81%	<input type="checkbox"/>	39%	<input type="checkbox"/>	29%	<input type="checkbox"/>
Big Data Ideation and Assessment [VBH15]	86%	<input type="checkbox"/>	28%	<input type="checkbox"/>	29%	<input type="checkbox"/>
Data Science Edge [GPP17]	67%	<input type="checkbox"/>	28%	<input type="checkbox"/>	43%	<input type="checkbox"/>
MIDST [CSR+19]	10%	<input type="checkbox"/>	89%	<input type="checkbox"/>	24%	<input type="checkbox"/>
Data Science Workflow [Guo12]	24%	<input type="checkbox"/>	50%	<input type="checkbox"/>	48%	<input type="checkbox"/>
Development Workflows for Data Scientists [Byr17]	33%	<input type="checkbox"/>	44%	<input type="checkbox"/>	43%	<input type="checkbox"/>
AI Ops [Tho19]	48%	<input type="checkbox"/>	33%	<input type="checkbox"/>	24%	<input type="checkbox"/>
CRISP-DM [She00]	67%	<input type="checkbox"/>	0%	<input type="checkbox"/>	33%	<input type="checkbox"/>
Foundational Methology for Data Science [Rol15]	67%	<input type="checkbox"/>	0%	<input type="checkbox"/>	29%	<input type="checkbox"/>

Diese Data Science Vorgehensmodelle eignen sich für die gewählte Aufgabe zur Spezifikation nur in bedingtem Maße aufgrund ihres Fokus auf einen einzelnen Anwendungsfall. Vorgehen zur Planung, Konzeption und Integration von einer Grundmenge an Use Cases gibt es in Teilaspekten bereits. Um diesem Rechnung zu tragen, wird auf das Vorgehen des Method-Engineerings nach BRINKKEMPER (vgl. Bild A-25, [Bri96]) zurückgegriffen um den ganzheitlichen Betrachtungswinkel des für die Spezifikationstechnik benötigten Vorgehens zu entsprechen.

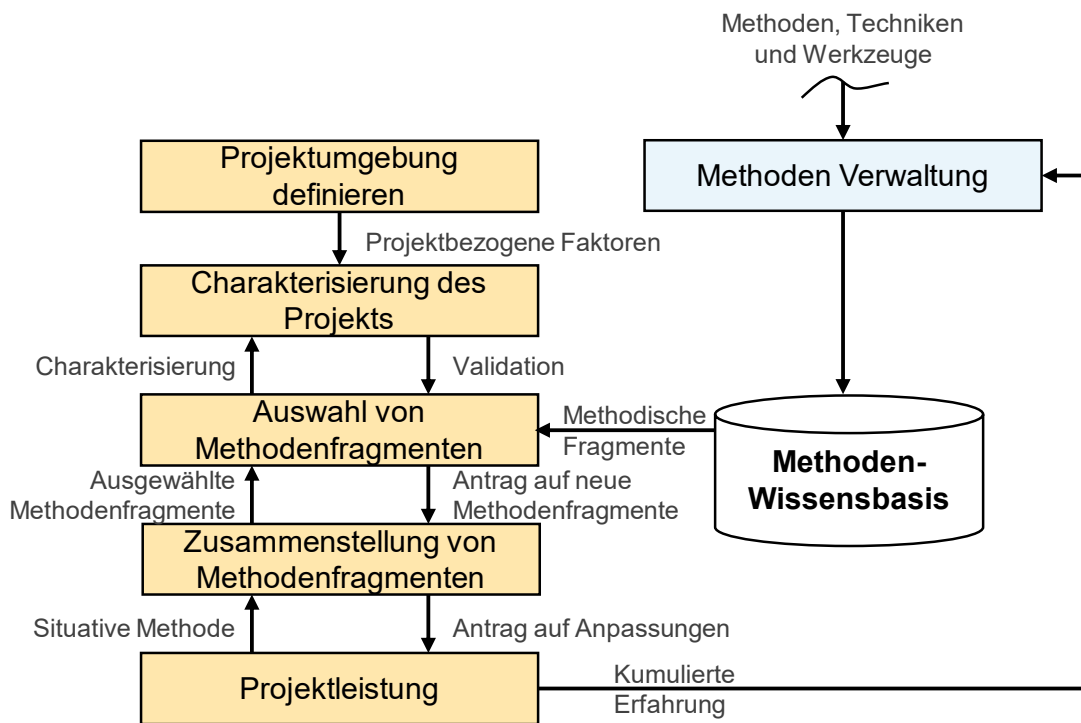


Bild A-25: Instanziierung des Vorgehens des Method Engineering für die Spezifikationstechnik nach BRINKKEMPER [Bri96, S. 277]

Zur Bestimmung der benötigten Vorgehensschritte und Partialmodelle gilt es zuerst, die relevanten Rollen sowie deren Zuordnung zu den Aktivitäten im Vorgehensmodell vorzunehmen. Teile der Ergebnisse beruhen auf Prescriptive Analytics Spezifika, übergreifend sind aber alle Phasen auf generelle Analytics Use Case Entwicklungen zu beziehen. Die folgenden Phasen (vgl. Vorgehensmodell Kapitel 4.3.1) werden zusätzlich in Form von Begleitaktivitäten berücksichtigt. Alle folgenden Aktivitäten sind aus der Literatur abgeleitet und entsprechen typischen Aktivitäten und Herausforderungen in Analytics Use Case Entwicklungsprojekten. In Bild A-26 werden die Aktivitäten den relevantesten Rollen zugeordnet. Eine direkte Zuordnung von Informationsbedarfen (Herausforderungen, Aktivitäten und Rollen) zu den Partialmodellen ist dem Anhang zu entnehmen (siehe Anhang A3.2). Die Begleitaktivitäten werden von allen beteiligten Rollen unterstützt und sind unternehmensspezifisch zu detaillieren. Hierzu können auch Aspekte des Change-Managements und der Verankerung in der Unternehmenskultur gezählt werden.

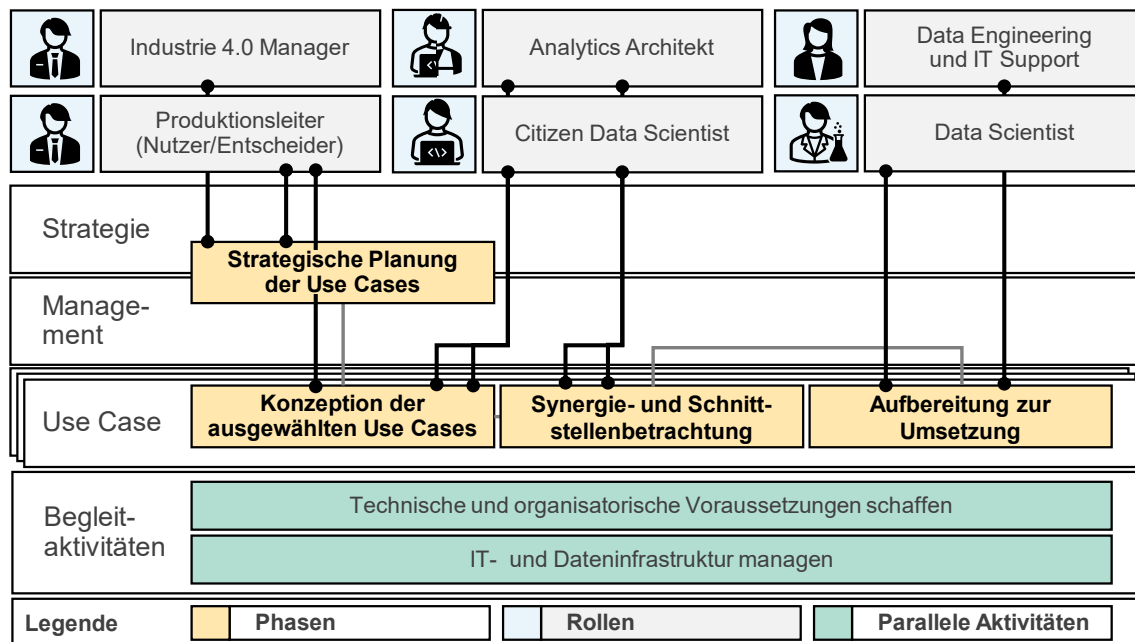


Bild A-26 Spezifische Aktivitäten der relevanten Stakeholder in der Planung, Konzeption und Integration von Prescriptive Analytics Lösungen

Es folgt eine Aufzählung der relevanten Aktivitäten und Informationsbedarfe in den Phasen:

- **Strategische Planung der Use Cases** (siehe Kapitel 2.5.3): Übergreifendes Zusammenspiel managen, Systemintegration [Mer16, S. 104, NSM+20, S. 735, WWS+24, S. 3] und Data Analytics Projekte vorplanen [ENM+20, S. 2, KML+19, S. 4]. Eine Auswahl der richtigen Use Cases ist essenziell in Bezug auf die Wirtschaftlichkeit (siehe Kapitel 2.3.2). Aufwände zur Use Case Entwicklung sind durch fehlende Wiederverwendung von Daten in der Praxis hoch [KGK23, S. 149].
- **Konzeption der ausgewählten Use Cases** (siehe Kapitel 2.5.5): Ablauf/Interaktion im Use Case managen [ENM+20, S. 10] und allgemeine Konzeption der Architektur [KJR+18, S. 164, HSP+21, S. 7]. Abläufe zur Verwendung des Use Cases müssen konzeptioniert werden [WZ23, S. 4]. Zusammenhänge innerhalb des Use Cases und zu anderen Use Cases müssen identifiziert und konzeptioniert werden ([KJR+18, S. 164, SOL+22, SOL+22, S. 5]). Für Prescriptive Analytics wird eine strukturierte einheitliche Pipeline benötigt (vgl. [LBA+20]). Außerdem fehlt für Prescriptive Analytics eine Übersicht über mögliche verwendbare Daten [BUB16, S. 63, KGK23, S. 149, WMK+24] (siehe Kapitel 2.4.3).
- **Synergie und Schnittstellenbetrachtung** (siehe Kapitel 4.6.2): Abstimmen der IT- und Dateninfrastruktur [AAE23, S. 11] und Analytics Projekt Synergien aufdecken [GKD23, EWB+24, Stu18, S. 45]. Analytics Use Case Entwicklung muss in der Organisation **verankert** werden [KNS+23, S. 913, NSM+20, S. 737]. Ge-

nerell scheitert die Einführung von Analytics Lösungen an einer mangelnden Integration in unternehmensspezifische Abläufe (übergeordnet im Geschäftsprozess [HHS24, S. 32] und in der Interaktion im einzelnen Use Case [EWB+24]). Die Integration in IT/OT ist eine verbreitete Herausforderung in Forschung und Praxis [WWS+24, S. 3]. Außerdem scheitern die Entwicklungsvorhaben in der Regel an einer fehlenden Verankerung in Unternehmensabläufen [Jop21, S. 119, MVO21, S. 8]. Analytics Use Cases basieren auf einer spezifischen IT-Infrastruktur, in die diese integriert werden müssen [KSM23, S. 29]. Prescriptive Analytics Use Cases müssen in die Architektur und Abläufe der Produktion **integriert** werden (siehe Kapitel 2.5.1) [SXX+20]. Diese Herausforderungen werden primär von der Praxis identifiziert, aus der Forschung heraus aber noch nicht adäquat adressiert [WWS+24, S. 9].

- **Aufbereiten zur Umsetzung** (siehe Kapitel 2.5.6): Bei der **Umsetzung** von Analytics Use Cases werden in der Regel nicht aufeinander abgestimmte Inseln erzeugt [Del16, S. 10, IHB+18, S. 974, MVO21, S. 5]. Dies verringert die Skalierbarkeit und Übertragbarkeit von entwickelten Lösungen.

Für die Erarbeitung der Methoden-Wissensbasis werden Vorgehensmodelle aus dem Stand der Technik sowie weitere relevant analysiert. Eine kurze Beschreibung des Wesenskerns der Vorgehensmodelle ist in Tabelle A-15 bereitgestellt.

*Tabelle A-15: Überblick über die verschiedenen für die Ausarbeitung relevanten Vorgehensmodelle*

	<b>Quelle</b>	<b>Kurzbeschreibung</b>	<b>Vorgehenstyp</b>
<b>Data Science</b>	[She00]	Geschäftsverständnis, Datenverständnis, Datenvorbereitung, Modellierung, Evaluierung, Deployment.	Iterativ
	[NSM+20]	Siehe CRISP-DM, Erweiterung um Projekt- und Change-Management.	Iterativ
	[HWS+19]	Siehe CRISP-DM, Erweiterung um technische Realisierungsaspekte in der physischen Welt (Shopfloor).	Iterativ
<b>Engineering</b>	[ENM+20]	Use Case Planung (Potenzialanalyse, Domänen und Datenanalyse), Use Case Entwicklung, Use Case Integration.	Sachlogisch
	[Mer16]	I4.0 Analyse, I4.0 Zielbestimmung, I4.0 Maßnahmenumsetzung (Projekte, Prozesse, Organisation, Technologien, Mitarbeitende).	Iterativ
	[BHF+23]	Use Case Auswahl, prototypische Implementierung eines Use Cases, Ableiten einer skalierbaren IT-Architektur, Implementierung weiterer Use Cases.	Iterativ
<b>Management</b>	[KML+19]	Identifikation und Strukturierung von I4.0 Use Cases, Vorselektion, Bewertung und Priorisierung, Wirtschaftlichkeitsanalyse priorisierter Use Cases.	Sachlogisch
	[GKD23]	Übergeordnete Ist-Analyse, Use Case Quick Check, Zielbildbestimmung und Auswahl, Anforderungsanalyse, Maßnahmendefinition, Querschnittsthemen und Roadmapping.	Sachlogisch mit Sync. Punkten

Diese werden basierend auf ihrer Flughöhe und den vorgeschlagenen Phasen untersucht (vgl. Bild A-28).

			Flughöhe			Vorgeschlagene Phasen			
			Strategisch	Taktisch	Operativ	Planung	Konzeption	Umsetzung	Synchronisation
Data Science	CRISP-DM	[She00]							
	IDS Implementierungsempfehlungen	[NSM+20]							
	CRISP DM 4 Manufacturing	[HWS+19]							
Engineering	Implementierung und Transfer von Predictive Analytics	[ENM+20]							
	I4.0 Einführung	[Mer16]							
	Use Case Rollout Planung	[BHF+23]							
Management	I4.0 für Logistik Kohl	[KML+19]							
	Human AI Collaboration	[GKD23]							

Bild A-27: Überblick über relevante Methoden als Grundlage für das Vorgehen des Method Engineering für die Methoden-Wissensbasis

### A3.2 Herleitung des Modellierungskonzepts

Das Vorgehen zur Erarbeitung des Modellierungskonzepts wird in Bild A-28 abgebildet (vgl. [WD25]). Es basiert auf der Erarbeitung der Elemente eines abgestimmten Modellierungskonzepts basierend auf der ISO/IEC/IEEE 42010:2022 und dem Vorgehen der DSRM nach PEFFERS ET AL. [IEC42010, PTR+07]. Für den Workshop zum Ableiten der Aktivitäten wurde das erweiterte Projektteam aus dem *VIP4PAPS* Projekt hinzugezogen.

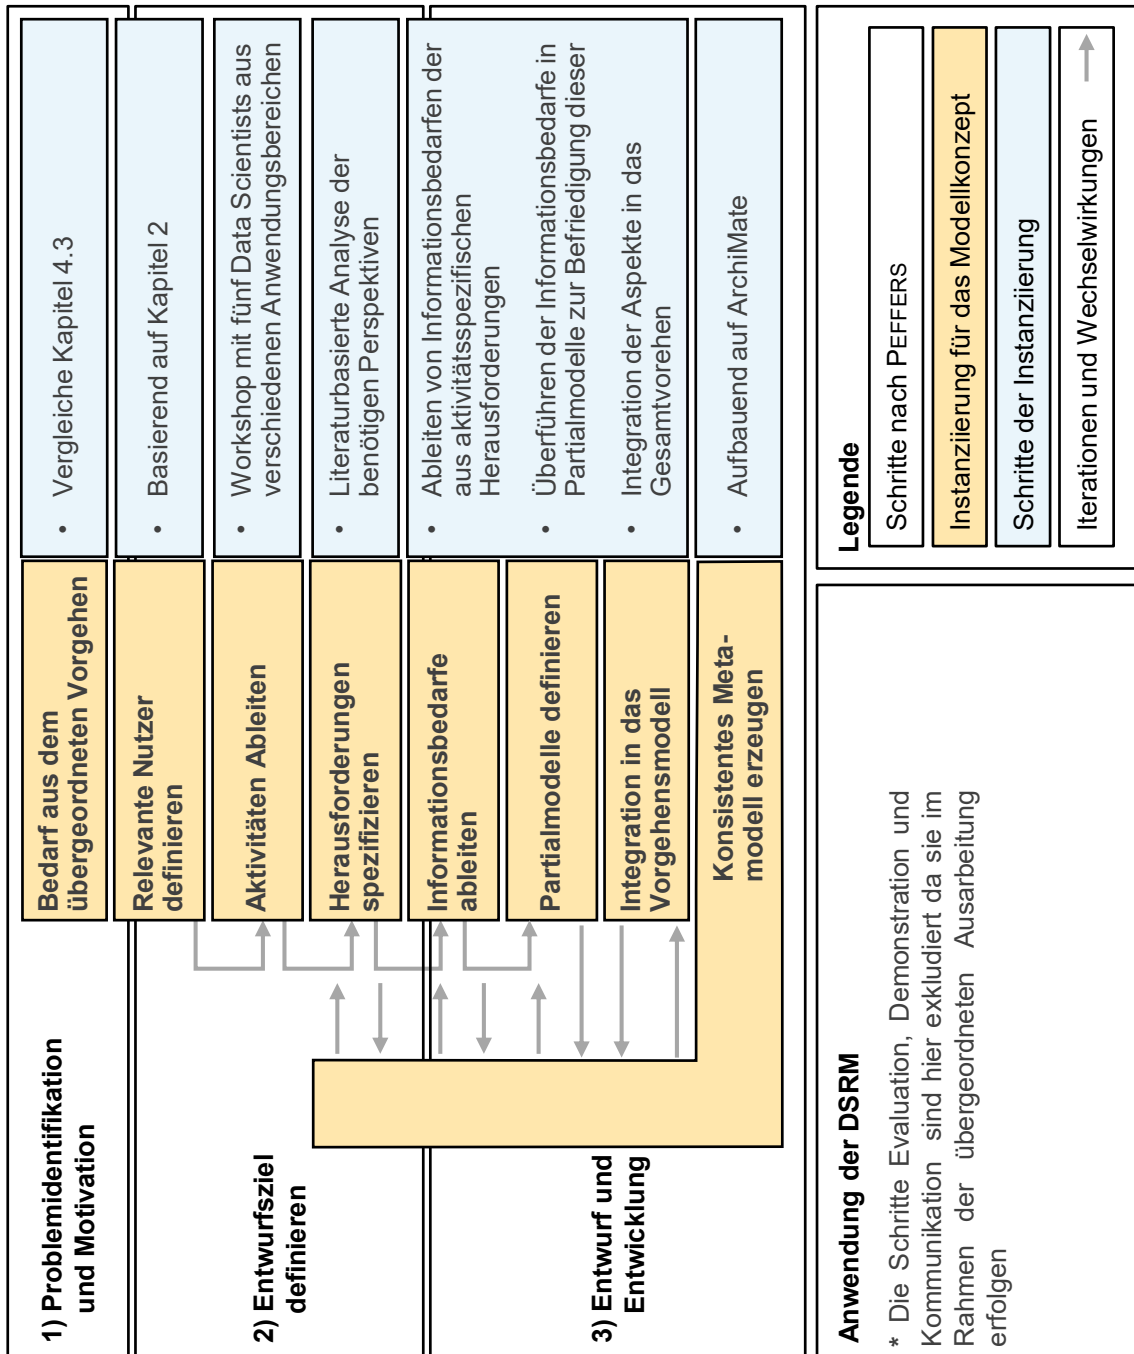


Bild A-28: Vorgehen bei der iterativen Erarbeitung des Modellierungskonzepts der Spezifikationstechnik aufbauend auf PEFFERS ET AL. [PTR+07]

### A3.3 Forschungsvorgehen der Artefakte

Im folgenden Kapitel werden ergänzende Informationen zum Forschungsdesign und vorgehen je Artefakt der Spezifikationstechnik gegeben. Dafür wird auf die folgenden Artefakte eingegangen:

- Design Prinzipien für Prescriptive Analytics Use Cases in der Produktion
- Taxonomie und Transformation Canvas für Prescriptive Analytics Use Cases in der Produktion
- Prescriptive Analytics Capability Map für die Produktion
- Referenzpipeline für Prescriptive Analytics Use Cases und Referenzarchitektur für die Integration von Prescriptive Analytics Use Cases in die Produktion
- Prescriptive Analytics Data Canvas

#### **Forschungsmethode zur Erarbeitung der Design Prinzipien für Prescriptive Analytics Use Cases in der Produktion**

Das Artefakt wurde in [WME+24] erarbeitet. Dort können ergänzende Informationen zum Forschungsdesign entnommen werden. Der Ansatz zur Identifikation geeigneter Design Prinzipien für Prescriptive Analytics Use Cases in der Produktion basiert auf der Methode von MÖLLER ET AL. [MGO20]. Bei der Entwicklung der Prinzipien wird sich am unterstützenden Ansatz angelehnt. Dieser wird mit Erkenntnissen aus der Literatur und eigenen Erfahrungen mit Prescriptive Analytics Systemen angepasst (vgl. Bild A-29). Bei unterstützenden Ansätzen liegt der Schwerpunkt auf der Vorgabe von Prinzipien vor dem Entwurf eines neuen Artefakts. Eine strukturierte Literaturrecherche nach KITCHENHAM ET AL. [KPB+09] wird durchgeführt, um eine geeignete Wissensbasis zur Ableitung von Gestaltungsprinzipien aus bestehenden Prescriptive Analytics Use Cases in Smart Factories zu schaffen. Die Wissensbasis wird durch eine eigene Implementierung eines Prescriptive Analytics Use Cases angereichert (siehe Kapitel 5.1). Die Designprinzipien werden nachfolgend in einem Workshop innerhalb eines Forschungskonsortiums validiert, um sie für einen neuen Prescriptive Analytics Use Case aus einem anderen Fokusbereich zu verwenden und anhand der Kriterien von MÖLLER ET AL. zu validieren [MGO20].

Der Rechercheansatz für die strukturierte Literaturrecherche ist in Bild A-29 visualisiert. Die iterative Entwicklung des Suchbegriffs führte zu der Notwendigkeit, Synonyme für das Wort "Produktion" zu verwenden. Aufgrund der Qualitätskriterien (Fokus auf Use Cases) wurden alle Reviews und Umfragen, die sich auf Prescriptive Analytics (z. B. auf Umsetzungstechniken) konzentrieren, verworfen. Es wurden alle Use Cases aufgenommen, die angeben, welche Art von Prescriptive Analytics Technik sie anwenden und welche Art von Daten sie verwenden. Weitere Qualitätskriterien waren, dass die Use Cases in einem realen Szenario implementiert wurden und dass klare Grenzen gesetzt wurden, um den Umfang des Use Cases zu definieren.

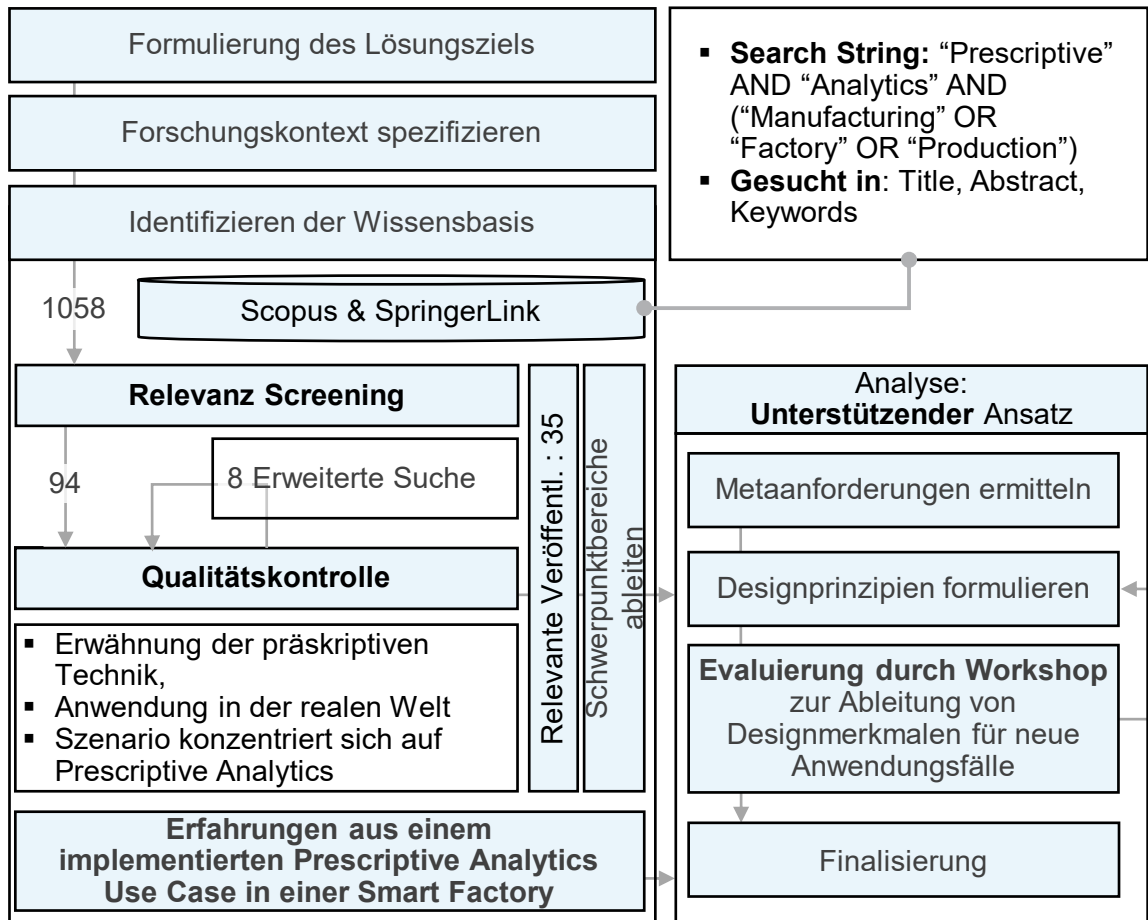


Bild A-29: Vorgehen zur Erarbeitung der Design Prinzipien aufbauend auf [MGO20] (Zahlen: Menge an analysierter Literatur)

## Forschungsmethode zur Erarbeitung der Taxonomie für Prescriptive Analytics Use Cases in der Produktion und der Prescriptive Analytics Use Case Transformation Canvas

Das Artefakt wurde in [WNG+25] erarbeitet. Dort können ergänzende Informationen zum Forschungsdesign entnommen werden. Das Forschungsdesign dieses Artefakts basiert auf NICKERSON ET AL. (konzeptioneller nach empirischer Ansatz) [NVM13]. Es wurden Schritte aus dem empirisch-konzeptionellen Ansatz hinzugefügt, um Anregungen aus der Praxis und der vorhandenen Literatur einzubeziehen. Ein Überblick über den Ansatz ist Bild A-30 zu entnehmen. Es wurde sich für Ansatz entschieden, um alle relevanten Dimensionen zu berücksichtigen, die bereits in der existierenden Literatur veröffentlicht wurden.

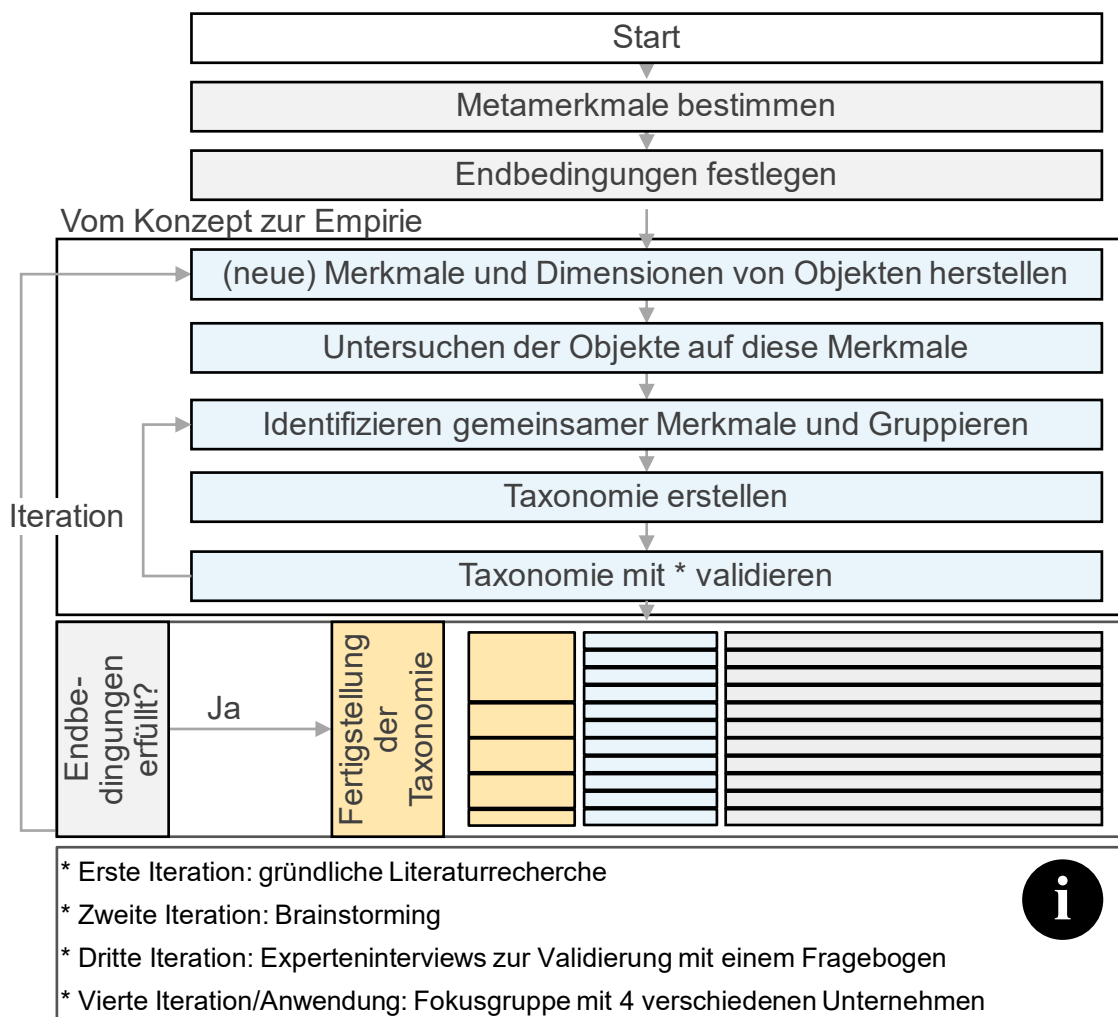


Bild A-30: Vorgehen zur Erarbeitung der Transformation Canvas und Taxonomie aufbauend auf [NVM13]

Auf dieser Grundlage wurden vier Iterationsschleifen durchgeführt:

- (1) **Gründliche Literaturrecherche:** Es wird auf der in [WME+24] durchgeführten strukturierten Literaturrecherche aufgebaut. Diese wird um eine Vorwärts- und Rückwärtssuche erweitert. Aufgrund des zeitlichen Abstands zwischen [WME+24] und dieser Ausarbeitung wird eine ergänzende gründliche Literaturrecherche in der Literatur durchgeführt, die zwischen [WME+24] und Dezember 2024 veröffentlicht wurde.
- (2) Die initiale Taxonomie aus (1) wurde in einem **Workshop** analysiert und erweitert. Hierfür wurde der Brainstorming-Ansatz nach WILSON [Wil13] verwendet.
- (3) Die erste verfeinerte Version der Taxonomie wurde acht verschiedenen Experten aus Forschung und Industrie vorgestellt. Bei den **Experteninterviews** wird dem Ansatz von MYERS UND NEWMAN gefolgt [MN07]. Die Taxonomie wurde auf der Grundlage des Feedbacks der Experten verfeinert. Die demografischen Daten der Befragten sind in Tabelle A-16 aufgeführt. Offene Leitfragen im Interview dienten dazu, wichtige Kategorien abzuleiten, zu prüfen, welche Dimensionen verbesserungswürdig sind (und welche möglicherweise weggelassen werden sollten), sowie die Skalierbarkeit und Übertragbarkeit der Taxonomie zu überprüfen. Eine Likert-Skala wurde verwendet, um den allgemeinen Reifegrad der Taxonomie zu bewerten (Komplexität, Effizienz der Anwendung, Präzision der Formulierung, Ganzheitlichkeit). Es wurde eine Skala mit fünf aufsteigenden Kategorien verwendet.
- (4) Schließlich wurden zwei **Workshops** abgehalten. Die Taxonomie wurde verwendet, um Prescriptive Analytics Use Cases zu kategorisieren und ihre Anwendbarkeit zu prüfen. Ein reales Anwendungsszenario aus einer IoT Factory wurde zur Demonstration verwendet (vgl. [WMN+24]). Das Konzept der Workshops basiert auf BREEN [Bre06]. Alle Teilnehmer (insgesamt acht) kommen aus der Automobil-, Sondermaschinen-, Klebstoff-, Lebensmittel-, Stahl- und Konsumgüterindustrie.

Die Schleifen drei und vier wurden eingeführt, um die Akzeptanz der Praktiker in der Industrie sicherzustellen. In jeder Iteration wurden Endbedingungen verwendet, um sicherzustellen, dass jeder Entwicklungszyklus von den anderen getrennt ist. Zwischen den einzelnen Iterationen wurde die Taxonomie auf der Grundlage von NICKERSON ET AL. entsprechend den iterationsspezifischen Ergebnissen geändert. Aufbauend auf der Taxonomie wurde in Anlehnung an [PME+22] eine Canvas zur Nutzung in einem Workshopformat erstellt.

Tabelle A-16: Interviewteilnehmer zur Erarbeitung der Taxonomie (TN = Teilnehmer)

TN	Erfahrung	Tätigkeitsbereich	Industrie
7	4 Jahre	Regelungstechnik	Forschung
8	3 Jahre	SPS-Programmierung	Forschung
9	5 Jahre	Maschinelles Lernen	Forschung
10	4 Jahre	Process Mining	Beratung
11	10 Jahre	KI und Data Science	Forschung (vormals Beratung)
12	6 Jahre	Produktion	Sondermaschinenbau
13	8 Jahre	Logistik	Stahlindustrie
14	8 Jahre	Instandhaltung	Automobilindustrie

Basierend auf der Erarbeitung der Taxonomie wurde eine Canvas zur einfachen Nutzung in einem Workshop erzeugt. Darauf aufbauend werden die Schnittstellen zur Taxonomie in Bild A-31 dargestellt.

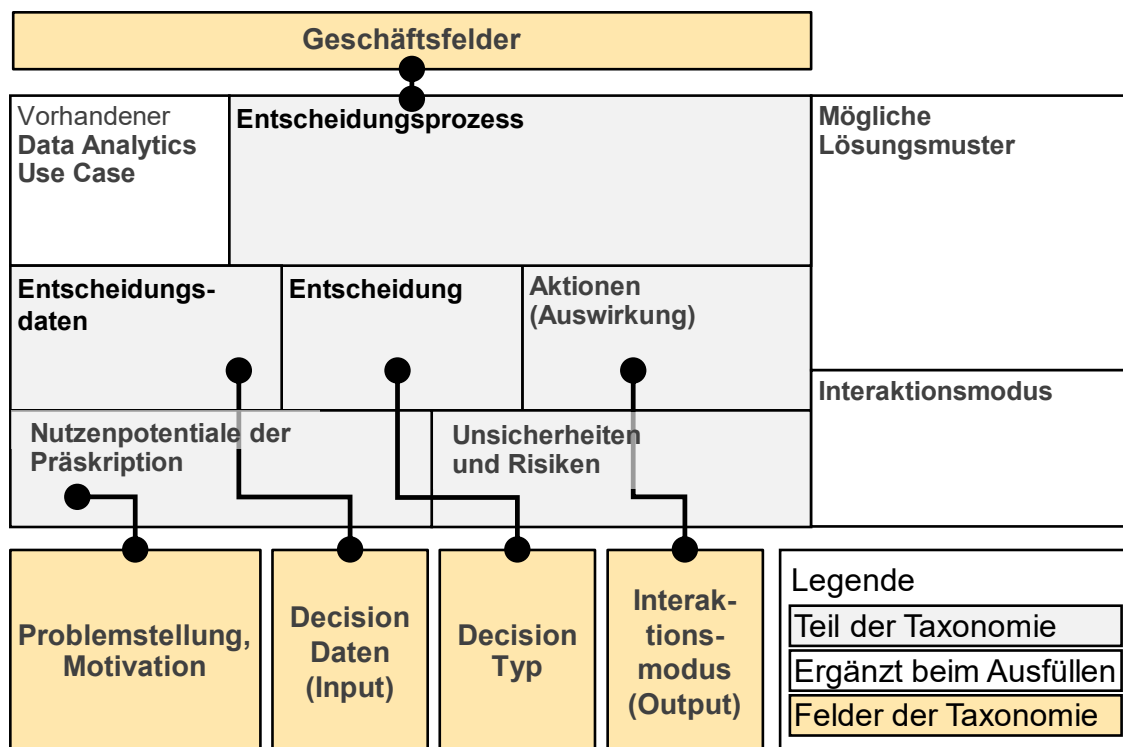


Bild A-31: Schnittstellen der Prescriptive Analytics Use Case Taxonomie und Use Case Transformation Canvas

## Forschungsmethode zur Erarbeitung der Prescriptive Analytics Capability Map für die Produktion

Das Artefakt wurde in [WLB+25] erarbeitet. Dort können ergänzende Informationen zum Forschungsdesign entnommen werden. Die Prescriptive Analytics Capability Map wurde nach dem Ansatz von VAN RIEL UND POELS entwickelt. [vP23]. Bild A-32 zeigt den instanziierten Forschungsansatz. Die Schritte zwei bis vier wurden dreimal durchlaufen. Jede Iteration umfasste mindestens einen Workshop, in dem die Capability Map angewendet wurde.

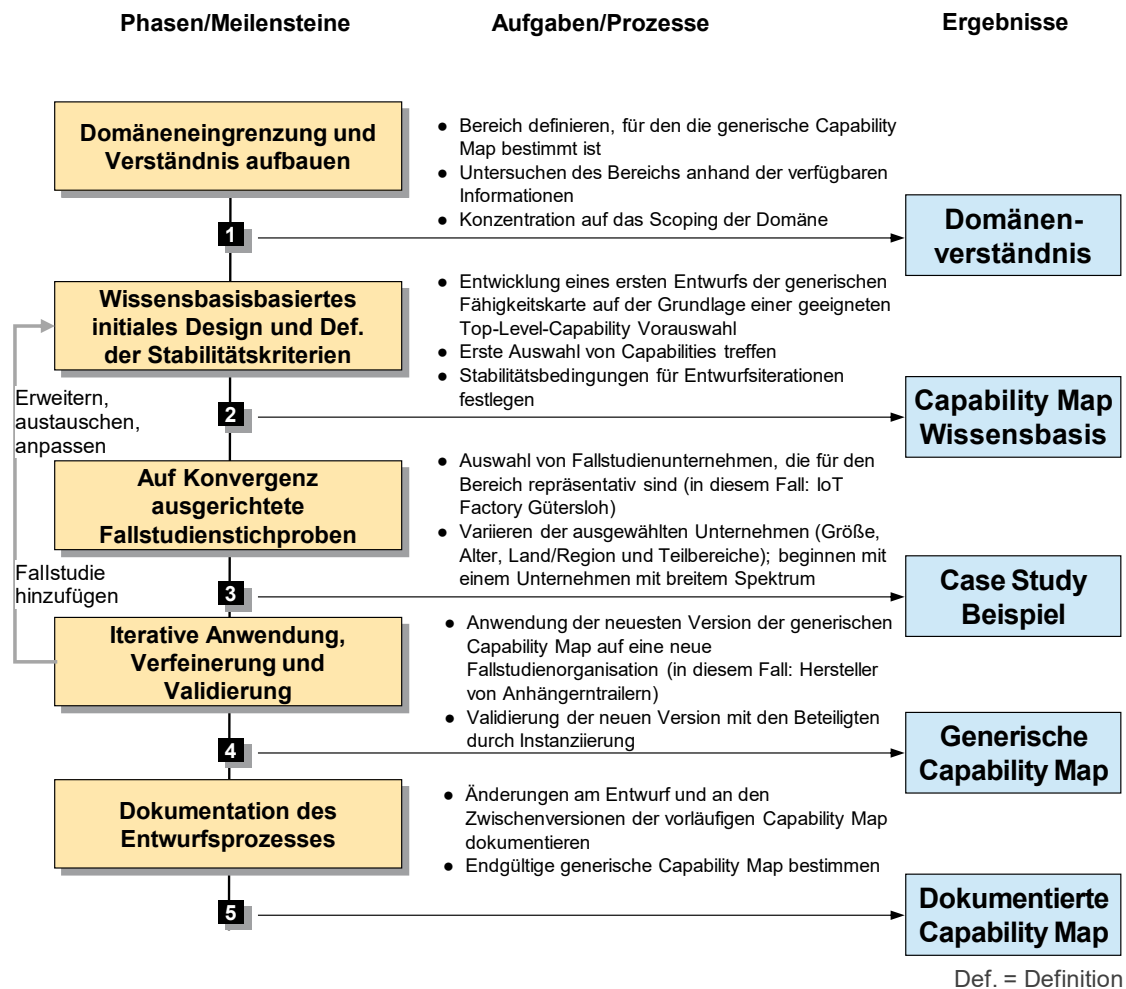


Bild A-32: Vorgehen zur Erarbeitung der Capability Map aufbauend auf [vP23]

Die Iterationen mit der jeweiligen Fallstudie erfolgten auf die hier beschriebene Art und Weise:

- (0) **Iteration 0:** Es wurden zwei Workshops mit einem Team an wissenschaftlichen Mitarbeitern durchgeführt. Diese dienen dazu, die ursprüngliche Capability Map zu verbessern. Das Team bezog Experten aus den Bereichen Fabrikplanung, Data Analytics, Process Mining und KI in der Produktion ein.
- (1) **Iteration 1:** Es wurde eine Fallstudie in einer IoT Factory in Gütersloh durchgeführt. Fünf Analytics Use Cases sind in dem gegebenen Szenario bereits implementiert. Auf der Grundlage dieser Erfahrungen wurde die Capability Map mit dem IoT-Factory-Laboringenieur überprüft.
- (2) **Iteration 2:** Die Capability Map wurde bei einem Trailer Hersteller mit 3.000 Mitarbeitern (weltweit) angewendet. Der Hersteller befindet sich auf der Industrie 4.0 Reifegradstufe Transparenz. Das Unternehmen implementiert derzeit 25 Analytics Use Cases in einer Fabrik. Die Iteration führte nur zu Anpassungen auf der detailliertesten Ebene der Capability Map.

Nach VAN RIEL UND POELS endet die Entwicklung einer generischen Capability Map, wenn die Stabilitätskriterien erfüllt sind. Ein gängiges Stabilitätskriterium ist, wenn keine Änderungen an den ersten beiden Fähigkeitsstufen auftreten [vP23]. Da dieses Kriterium in der zweiten Iteration erfüllt wurde, wird der initiale Designprozess als abgeschlossen angesehen.

## Forschungsmethode zur Erarbeitung der Referenzarchitektur und Referenzpipeline für Prescriptive Analytics Use Cases in der Produktion

Das Artefakt wurde in [WMN+24] erarbeitet. Dort können ergänzende Informationen zum Forschungsdesign entnommen werden. Für den Entwurf einer Referenzarchitektur wurde die von GALSTER UND AVGERIOU vorgeschlagene Methode verwendet [GA11]. Diese Methode wurde gewählt, weil sie sowohl praktische als auch forschungsorientierte Vorarbeiten berücksichtigt. Sie basiert auf einem empirisch fundierten Ansatz. Im Zusammenhang mit der vorgeschlagenen Methode bezieht sich "empirisch fundiert" auf die Notwendigkeit des Nachweises/der Nachvollziehbarkeit für jeden Baustein der Architektur [GA11, S. 154]. Die von GALSTER UND AVGERIOU entwickelte Methode sieht sieben Schritte für die Entwicklung einer Referenzarchitektur vor (vgl. Bild A-33). Im Folgenden wird die Instanziierung dieser Schritte die Entwicklung einer Referenzarchitektur zur Integration von Prescriptive Analytics erläutert.

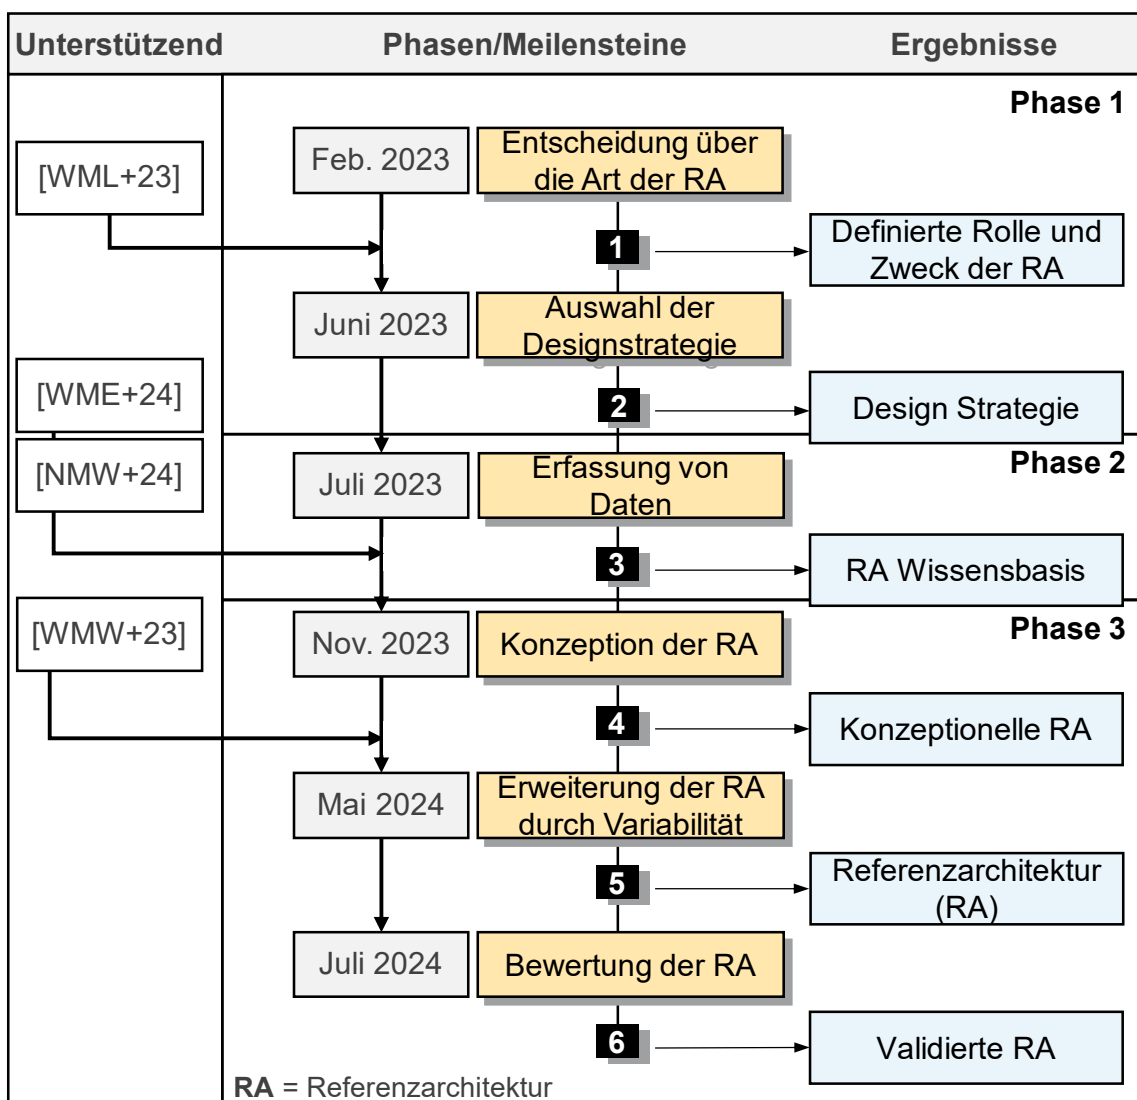


Bild A-33: Vorgehen zur Erarbeitung der Referenzpipeline und Referenzarchitektur aufbauend auf [GA11]

**Phase eins** befasst sich mit den vorbereitenden Aufgaben vor Beginn der eigentlichen Datenerfassungs- und Designphase für die Referenzarchitektur. Die Definition der Art der Referenzarchitektur (Schritt 1) führt zu einem definierten Zweck und einer festgelegten Rolle der Referenzarchitektur. Auf dieser Grundlage wird eine Entwurfsstrategie ausgewählt. Die Bewertung des Umfangs basiert auf [PP15], wie von Galster und Avgeriou [GA11] vorgeschlagen. Einen Überblick über die für die Anpassung der Methode erforderlichen Entwurfsentscheidungen gibt Bild A-34. Die Entscheidungen über das Gesamtdesign werden von der Art der angestrebten Referenzarchitektur beeinflusst.

Scope der Referenzarchitektur (RA)						
Basierend auf dem Verwendungskontext		Plattformspezifisch	Industriespezifisch	Industrieübergreifend		
Charakterisierung	Wann	Klassisch		Vorläufig		
	Wie	Normung		Erleichterung		
	Wo	Einzelne Organisation		Mehrere Organisationen		
Design Strategie						
Design Ansatz		Von Grund auf neu		Aufbauend auf bestehenden RA's		
Typ der RA		Forschungsorientiert		Praxisorientiert		
Datenakquirierung						
Datenakquise		Klassisch	Vorläufig	Plattformspezifisch	Branchenspez. RA's	
Erzeugung der Referenzarchitektur						
Perspektive		Funktional	Logisch	Technisch	Business	Kundenkontext
Variabilität		Annotation zu RA		Variabilitätsmodelle	Ansichten zur Variabilität	

Bild A-34: Scope der erarbeiteten Referenzarchitektur aufbauend auf [GA11]

**Phase zwei** konzentriert sich auf die Beschaffung von Daten für das Design der Referenzarchitektur. Zu diesem Zweck wurde eine Literaturrecherche durchgeführt. Auf der Grundlage der Entwurfsstrategie werden die benötigten Datenquellen identifiziert. Der Detaillierungsgrad wird festgelegt, um die Eingangsliteratur für den Entwurf weiter zu verfeinern. Dafür wurden folgende Recherchen herangezogen:

- Strukturierte Literaturrecherche mit Schwerpunkt auf Use Cases für Prescriptive Analytics in der Produktion (siehe Kapitel 2.4.1). [WME+24]
- Strukturierte Literaturrecherche mit Schwerpunkt auf Prescriptive Analytics Plattformen (siehe Kapitel 3.3.3). [NMW+24]
- Gründliche Literaturrecherche zu bestehenden Referenzarchitekturen (Ergebnisse siehe Kapitel 3.3.4).

**Phase drei** befasst sich mit dem eigentlichen Design der Referenzarchitektur. Die Bewertung des Beitrags basiert auf der Korrektheit und dem Nutzen der Referenzarchitektur

sowie auf der Unterstützung der Architektur für eine effiziente Anpassung und Instanziierung. Ein Teil der Evaluation besteht darin, bestehende Referenzarchitekturen auf die resultierende Architektur abzubilden [GA11, S. 157].

Der Evaluierungsschritt ist von größter Wichtigkeit, wenn die Referenzarchitektur von Grund auf neu erstellt wird [GA11, S. 157]. Die Qualität der Referenzarchitektur kann anhand ihrer Anpassungsfähigkeit, Verständlichkeit und Zugänglichkeit innerhalb einer Organisation gemessen werden [GA11, S. 157]. Die Funktionalität der Referenzarchitektur wird durch die Anwendung in der IoT Factory Gütersloh demonstriert. Auf dieser Grundlage wird die resultierende Architektur mit den Anforderungen verglichen (vgl. [WMN+24]). Die Überschneidung der Lösung mit bestehenden Architekturen wird untersucht. Schließlich werden qualitative Experteninterviews mit Industrieexperten durchgeführt, um die bereitgestellte Referenzarchitektur zu bewerten.

## Forschungsmethode zur Erarbeitung der Prescriptive Analytics Data Canvas für die Produktion

Das Artefakt wurde in [WME+24] erarbeitet. Dort können ergänzende Informationen zum Forschungsdesign entnommen werden. Das folgende Kapitel beschreibt die Anwendung der DSRM nach PEFFERS ET AL. (vgl. Bild A-35) zur Erarbeitung einer Prescriptive Analytics Data Canvas [PTR+07]. Die Designziele werden auf der Grundlage der Analyse aktueller Planungsbemühungen für Analytics Use Cases erstellt. Der Entwurf und die Entwicklung werden durch Methoden des papierbasierten Prototypings unterstützt. Die Demonstration wurde in der IoT Factory des CENTER FOR APPLIED DATA SCIENCE GÜTERSLOH durchgeführt. Zur Evaluierung wird das generierte Artefakt mit den Designzielen verglichen. Eine kritische Diskussion der Ergebnisse reflektiert den Beitrag unter Berücksichtigung des aktuellen Stands der Technik.

DSRM nach PEFFERS ET AL.	Implikationen und wichtigste Ergebnisse
<b>Problem- identifikation und Motivation</b>	<ul style="list-style-type: none"> <li>• Motivation für die Anwendung von Analytics in der Smart Factory und Definition von Prescriptive Analytics</li> </ul>
<b>Entwurfsziel definieren</b>	<ul style="list-style-type: none"> <li>• Herausforderungen bei der strategischen Planung von Prescriptive Analytics</li> <li>• Herausforderungen bei der Umsetzung von Prescriptive Analytics</li> </ul>
<b>Entwurf und Entwicklung</b>	<ul style="list-style-type: none"> <li>• Prescriptive Analytics Datenebenen</li> </ul>
<b>Demonstration</b>	<ul style="list-style-type: none"> <li>• Demonstration der Anwendbarkeit der Canvas-Anwendung zur Erstellung einer Roadmap</li> </ul>
<b>Evaluierung</b>	<ul style="list-style-type: none"> <li>• Integration in bestehende Literatur/Wissensbasis Reflexion der Ergebnisse gegenüber den Anforderungen</li> </ul>

Bild A-35: Vorgehen zur Erarbeitung der Prescriptive Analytics Data Canvas

## A4 Ergänzungen zur Demonstration und Evaluation der Spezifikationstechnik

Das Folgende Kapitel des Anhangs gibt einen Überblick über die ergänzenden Informationen zur Demonstration der Spezifikationstechnik.

### A4.1 Ausgefüllte Use Case Transformation Canvas

Die in Anhang A2.9 generisch abgebildete Use Case Transformation Canvas wird in Bild A-36 mitsamt den Workshopkarten für den Use Case Prescriptive Production Management abgebildet.

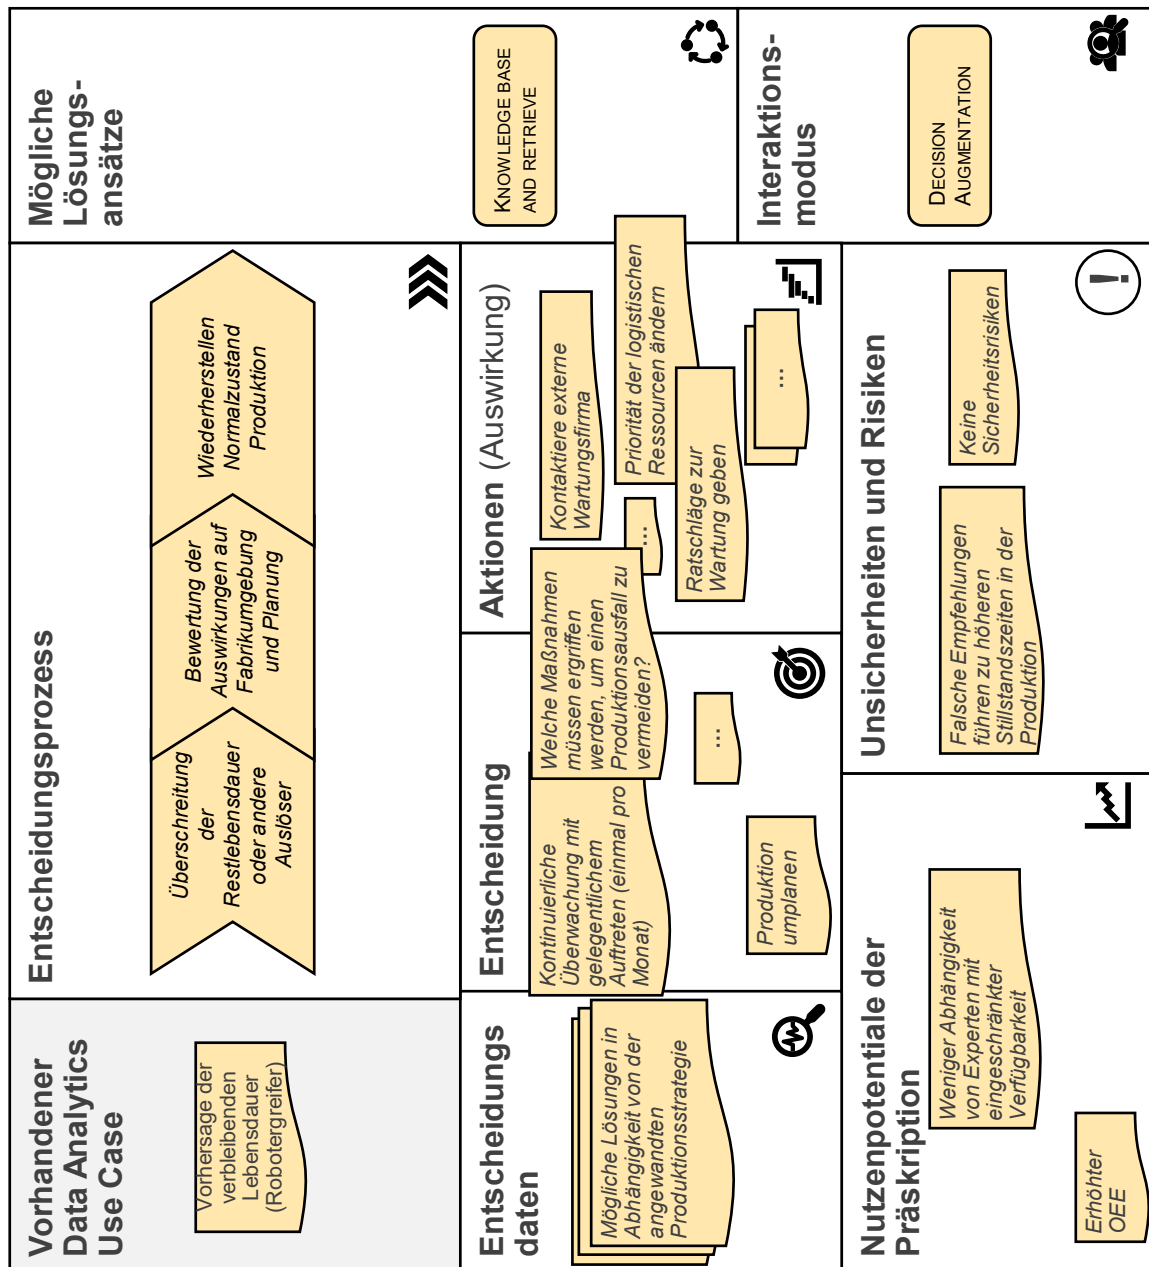


Bild A-36: Ausgefüllte Canvas für den Use Case Prescriptive Production Management

## A4.2 Initial bewertete Capability Map

Bild A-36 ist die für die IoT Factory bewertete Prescriptive Analytics Capability Map abgebildet.

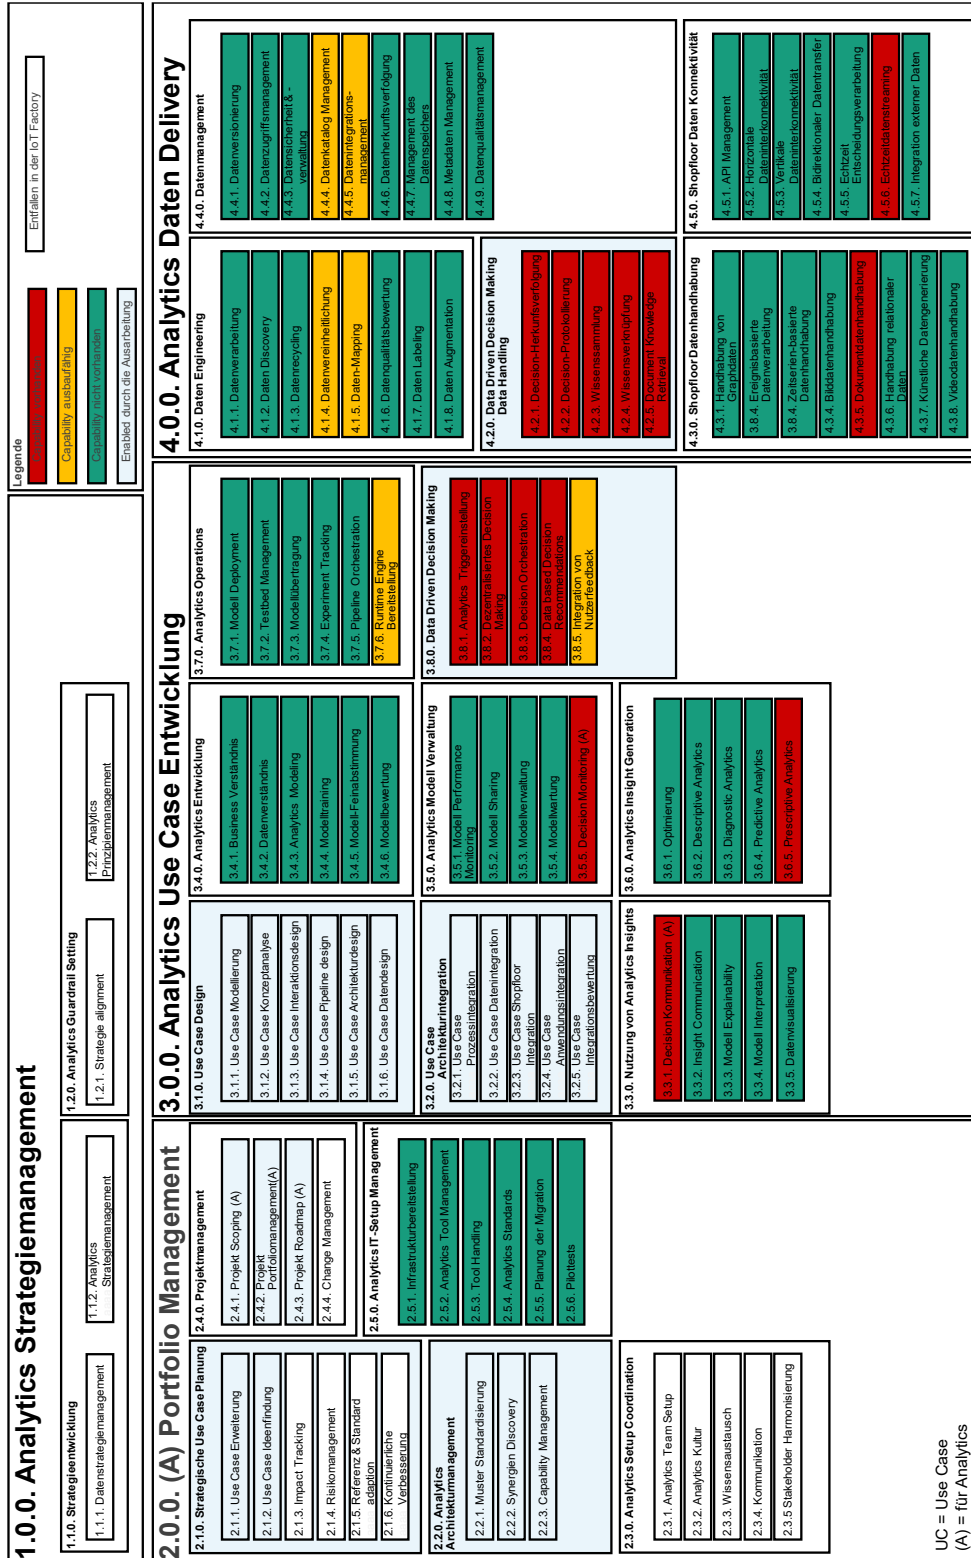


Bild A-37: Instanziierte Capability Map für die IoT Factory

### A4.3 Detailliertes Use Case Portfolio

In diesem Kapitel wird separat auf die Erkenntnisse der Aufwand-Nutzen-Abschätzung eingegangen. Zur initialen Priorisierung der Use Cases wird auf bewährte **Portfoliotech-niken** zurückgegriffen.

**Aufwand:** Zur Bewertung des Aufwandes werden die generischen, für die ausgewählten Prescriptive Analytics Use Cases relevanten, Capabilities des Unternehmens bewertet und zwischen den Use Cases ins Verhältnis gesetzt. Dabei ist eine vorherige Instanziierung der Capability Map in Phase eins essenziell. Basierend auf der Betrachtung der Capabilities wurden in der initialen Aufwandsbewertung unter anderem folgende Punkte festgestellt:

- **Analytics Trigger Einstellung** (3.8.1.): In der IoT Factory liegt bisher keine Möglichkeit vor, teilautomatisch Algorithmen auszulösen, wenn Ereignisse detektiert wurden. Dies ist eine Grundvoraussetzung für den Aufbau von teilautomatisierten oder autonomen Prescriptive Analytics Lösungen (Verknüpfung der Lösung mit dem Umfeld).
- **Decision Herkunftsverfolgung und Decision Protokollierung** (4.2.1. und 4.2.2.): Zur Bereitstellung von Mechanismen zur Verbesserung des Prescriptive Analytics Use Cases ist es essenziell, die getroffenen Entscheidungen nachvollziehbar zu dokumentieren.
- **Decision Kommunikation** (3.3.1.): Die in einem Prescriptive Analytics Use Case getroffenen Entscheidungen müssen kommuniziert werden. Dazu zählen die Fristgerechte und zielgerichtete Verteilung der Entscheidungen an die relevanten Akteure und Applikationen.

**Nutzen:** Zur weiteren Differenzierung der Use Cases wird deren Einfluss auf die strategischen Ziele eingeordnet. Nachfolgend ein Ausschnitt der strategischen Ziele die im Rahmen eines Workshops aufgenommen wurden:

- **Entlastung der Entscheider:** Aufgrund der auf Entscheider in kleinen und mittelständischen Unternehmen einwirkenden Einflüsse müssen Entscheidungen immer rascher getroffen werden [BUB16, S. 63]. Hier können Prescriptive Analytics Use Cases unterstützen, die kognitive Belastung von Führungskräften zu verringern um ihnen wiederkehrende Entscheidungen abzunehmen [RBD+17, S. 84].
- **Verringerung der Machine Downtime:** Diese stellt ein gängiges Optimierungsziel aus Produktionssystemen (vgl. [Bru17, S. 82]) dar und dient der Veranschaulichung für mögliche Industriekunden.
- **Unterstützung von ungeschultem Personal:** Im Rahmen der IoT Factory wird oft neues Personal eingesetzt. Jede Unterstützung beim Umgang mit fehlendem Detailwissen über die Fabrik ist ein strategisches Ziel.

Die Weiterentwicklung einer zukunftsrelevanten Fähigkeit kann auch als solches als Nutzen betrachtet werden. Eine Übersicht über weitere mögliche Use Cases in der IoT Factory ist in Bild A-38 abgebildet.

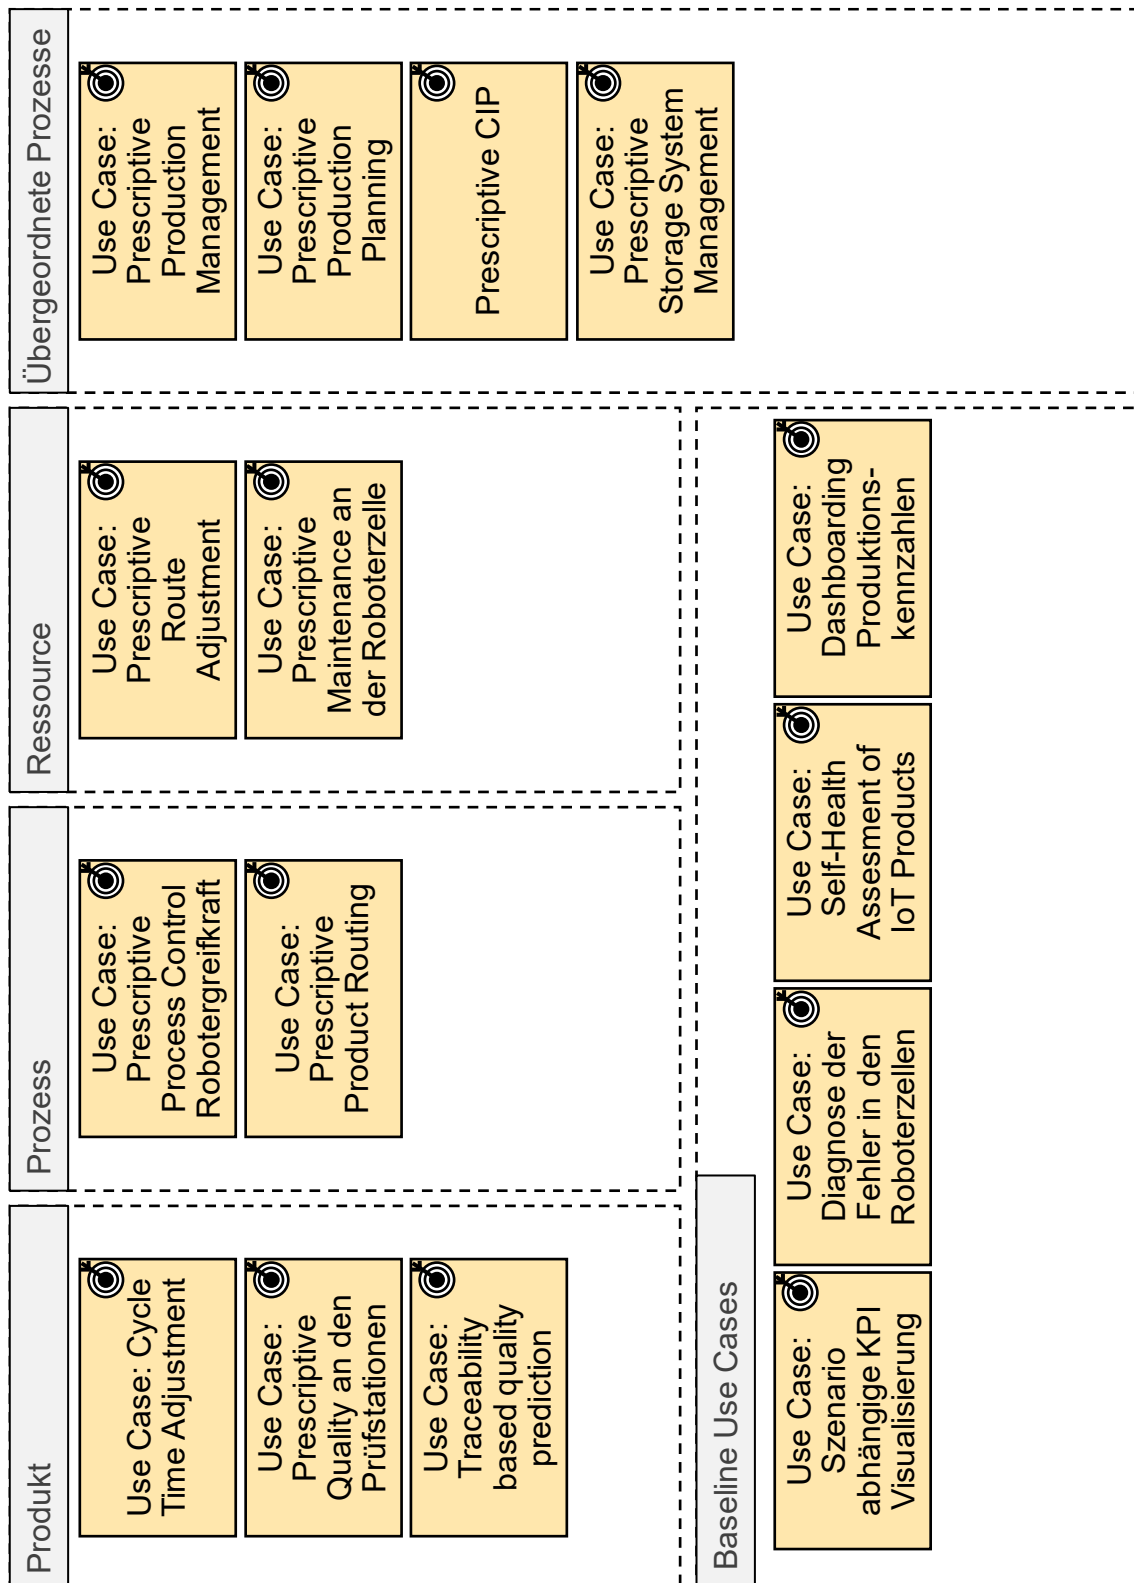


Bild A-38: Use Case Backlog der IoT Factory mit ausgewählten Use Cases und Backlog

### A4.4 Detaillierte Data Map

Im Rahmen der Standortbestimmung wird die Data Map zur Analyse der Unternehmensprozesse verwendet.

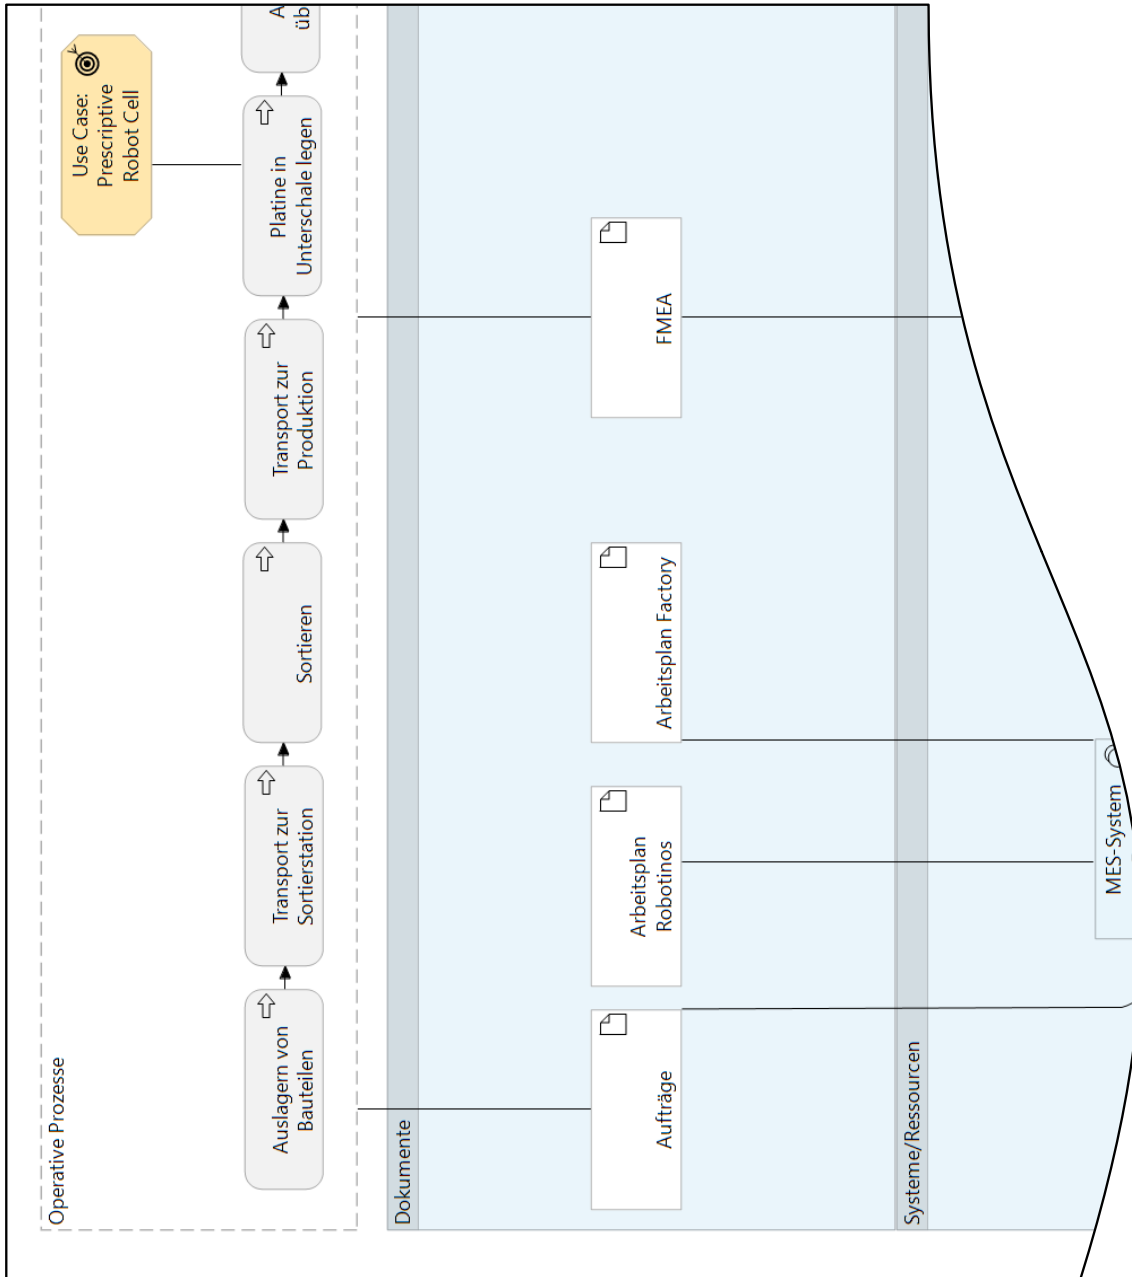


Bild A-39: Einblick in die Data Map der IoT Factory (übergeordnet)

## A4.5 Detaillierte Analytics Canvas

Im Rahmen der Spezifikation des Use Cases wird die Analytics Canvas herangezogen. Ein Ausschnitt der modellierten Ergebnisse ist Bild A-40 zu entnehmen.

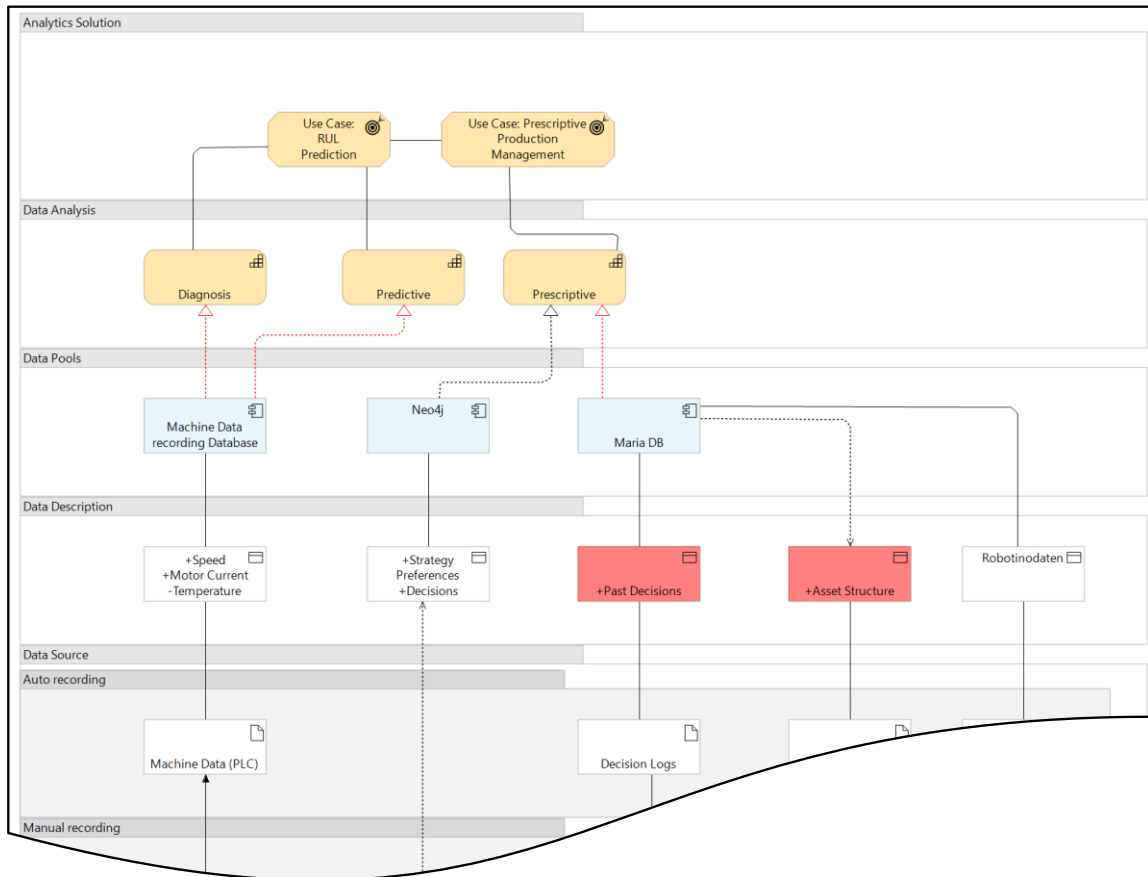


Bild A-40: Einblick in die Analytics Canvas (Use Case Applikationsarchitektur) des Prescriptive Production Management Use Cases

### A4.6 Detaillierte Applikationsarchitektur

Im Rahmen der Spezifikation des Use Cases wird die Applikationsarchitektur modelliert und angepasst. Ein Ausschnitt der aggregierten Architektur ist Bild A-41 zu entnehmen.

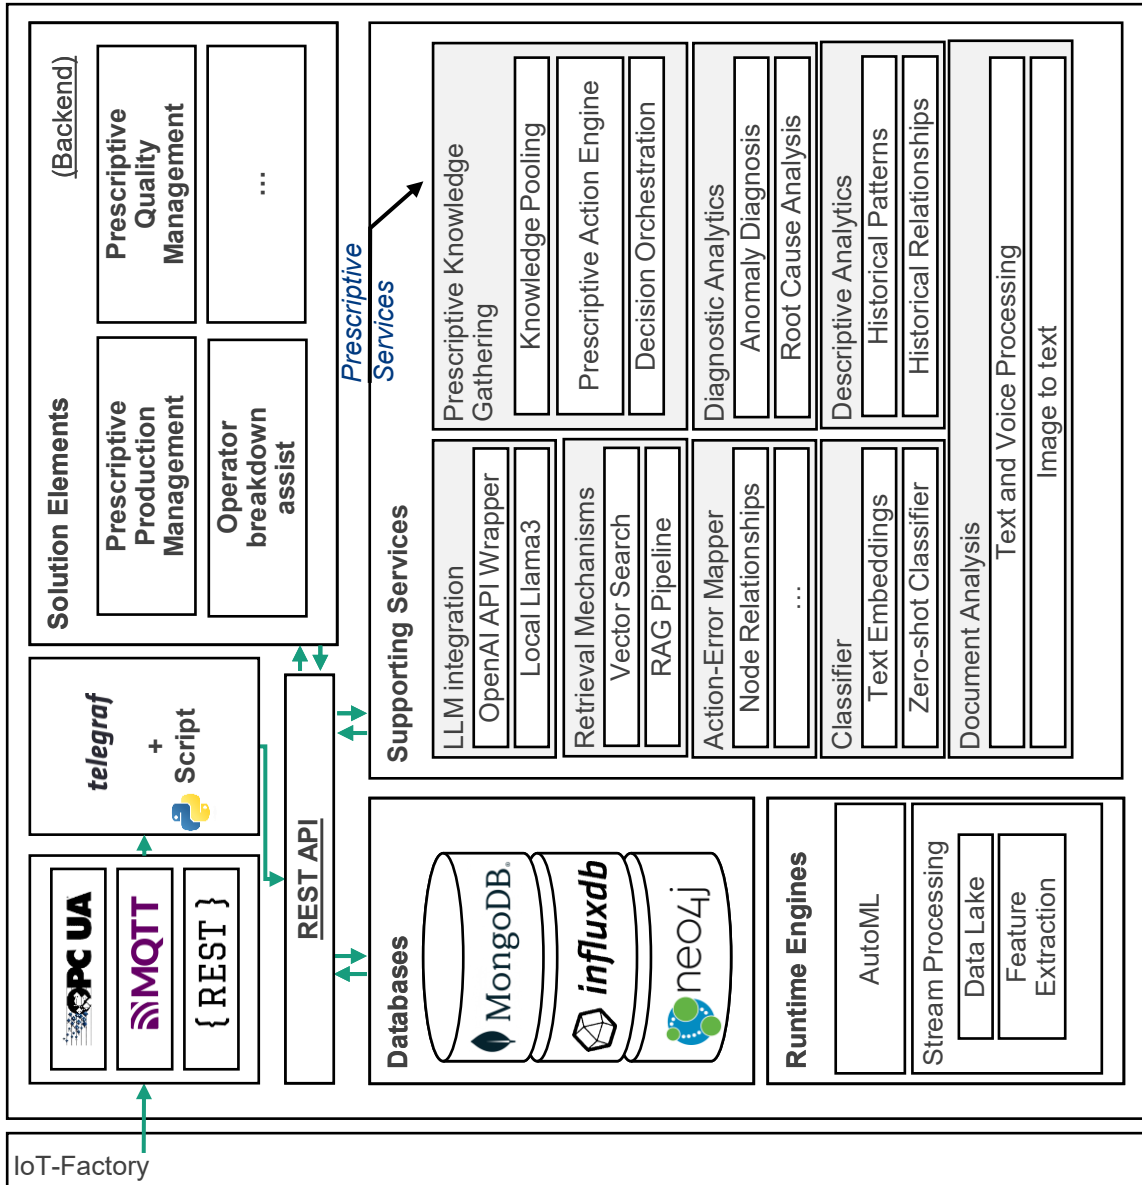


Bild A-41: Überblick zur Applikationsarchitektur der IoT Factory (aufbauend auf den Projektergebnissen des Validierungsforschungsprojektes VIP4PAPS)

### A4.7 Datenkatalog der IoT Factory

Im Rahmen der Spezifikation des Use Cases wird der Datenkatalog modelliert und angepasst. Ein Ausschnitt der modellierten Ergebnisse ist Bild A-42 zu entnehmen.

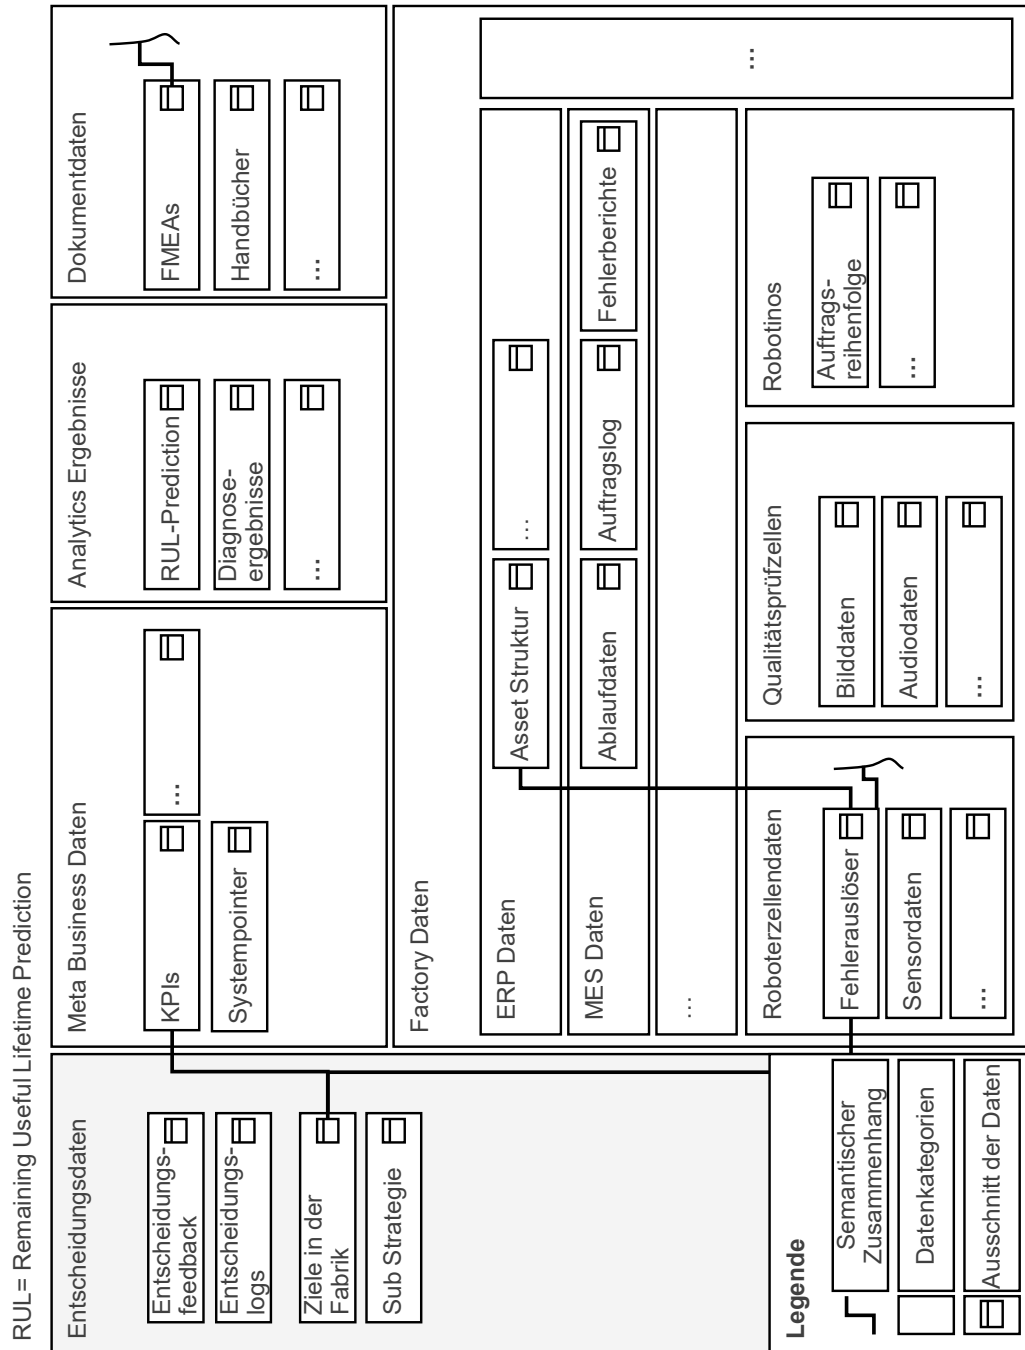


Bild A-42: Ausgefüllter Datenkatalog für die IoT Factory (übergeordnet)

## A4.8 Datenobjektbasierte Roadmap

Im Folgenden wird das Artefakt der datenbasierten Roadmap beschrieben. Es dient der Befüllung der Roadmap zur strategischen Planung einer ausgewählten Menge an Prescriptive Analytics Use Cases (**Phase drei**). Details zur Herleitung können der Veröffentlichung [WMK+24] entnommen werden.

Der Ansatz der Roadmap ist an sich etabliert und wurde in diversen Veröffentlichungen als adäquates Mittel zur Use Case Projekt- und Umsetzungsplanung verwendet. Roadmaps dienen als visueller Ansatz zur Konkretisierung von Strategien und Zielvorhaben hin zur Umsetzungsplanung [DPM+23, S. 5]. Sie dienen der Anregung von geführten Diskussionen zur Priorisierung und Anpassung von Reihenfolgen. Das Aufdecken von Synergien und Schnittstellen liegt im Vordergrund [DPM+23, S. vii]. Für genauere Erläuterungen der Grundmechanismen wird auf GAUSEMEIER UND PLASS [GP14, S. 166] verwiesen (z. B. angewendet im Kontext der Produktion durch [Pie24, S. 65]). Roadmaps können auf viele verschiedene Weisen visuell zugänglich gemacht werden (vgl. [PFP09, VP23, S. 3]). Im Folgenden wird sich auf eine einfache Variante konzentriert. Eine Übersicht, zu der im Rahmen der Ausarbeitung verwendeten Darstellungskonvention, ist Bild A-43 zu entnehmen. Es werden drei sogenannte „Swimlanes“ (Zeilen) verwendet. Eine Swimlane fasst die verschiedenen **Use Cases** zusammen. Eine weitere nennt die dafür zu erschließenden **Datenobjekte**. Die dritte Swimlane dient dem Querverweis zu übergreifenden **Initiativen** und Ansätzen.

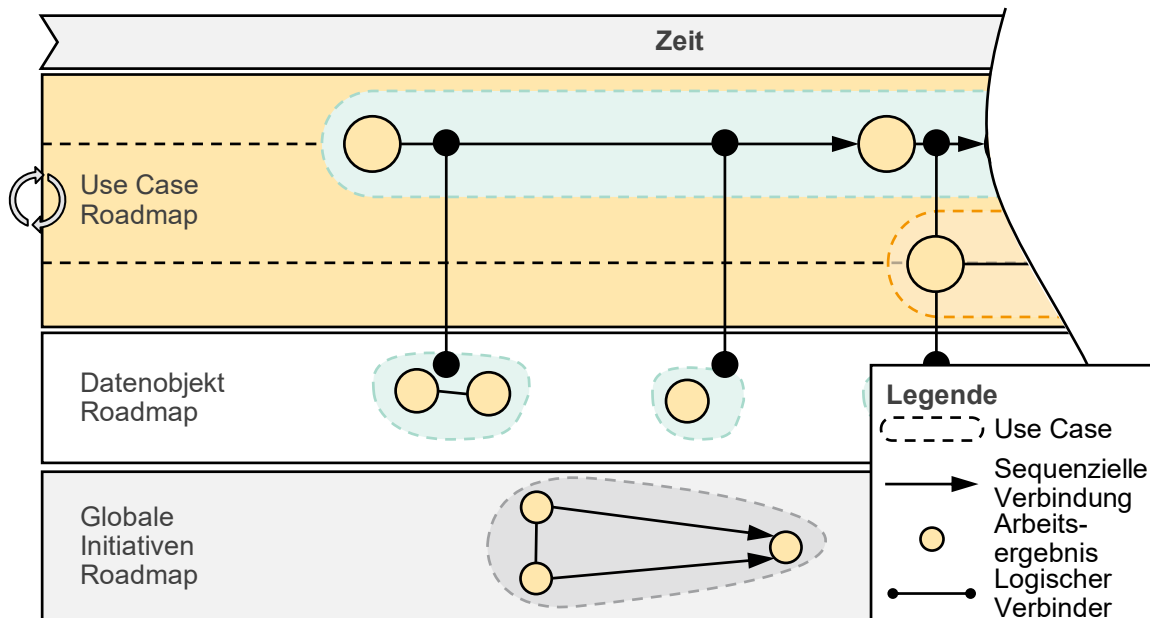


Bild A-43: Darstellung einer generischen Form einer Roadmap mit Swimlanes für Use Cases, zu erschließende Datenobjekte und übergreifende Projekte und Initiativen aufbauend auf [WMK+24]

Aufbauend auf der generischen Roadmap wird die spezielle Roadmap der IoT Factory in Bild A-44 dargestellt. Die Reaktion auf eine Änderung in der Produktqualität stellt eine Funktion der Auslastung der Produktion dar. Eine weitere Ausbaustufe des Prescriptive Production Management Use Cases auf die Stufe Audit (auch als Funktion der Entscheidungsstrategiedaten) ist vorgesehen, sobald die anderen Use Cases umgesetzt sind. Dies basiert primär darauf, dass der Prescriptive Production Management Use Case von der Vernetzung mit dem Output der anderen Use Cases profitiert.

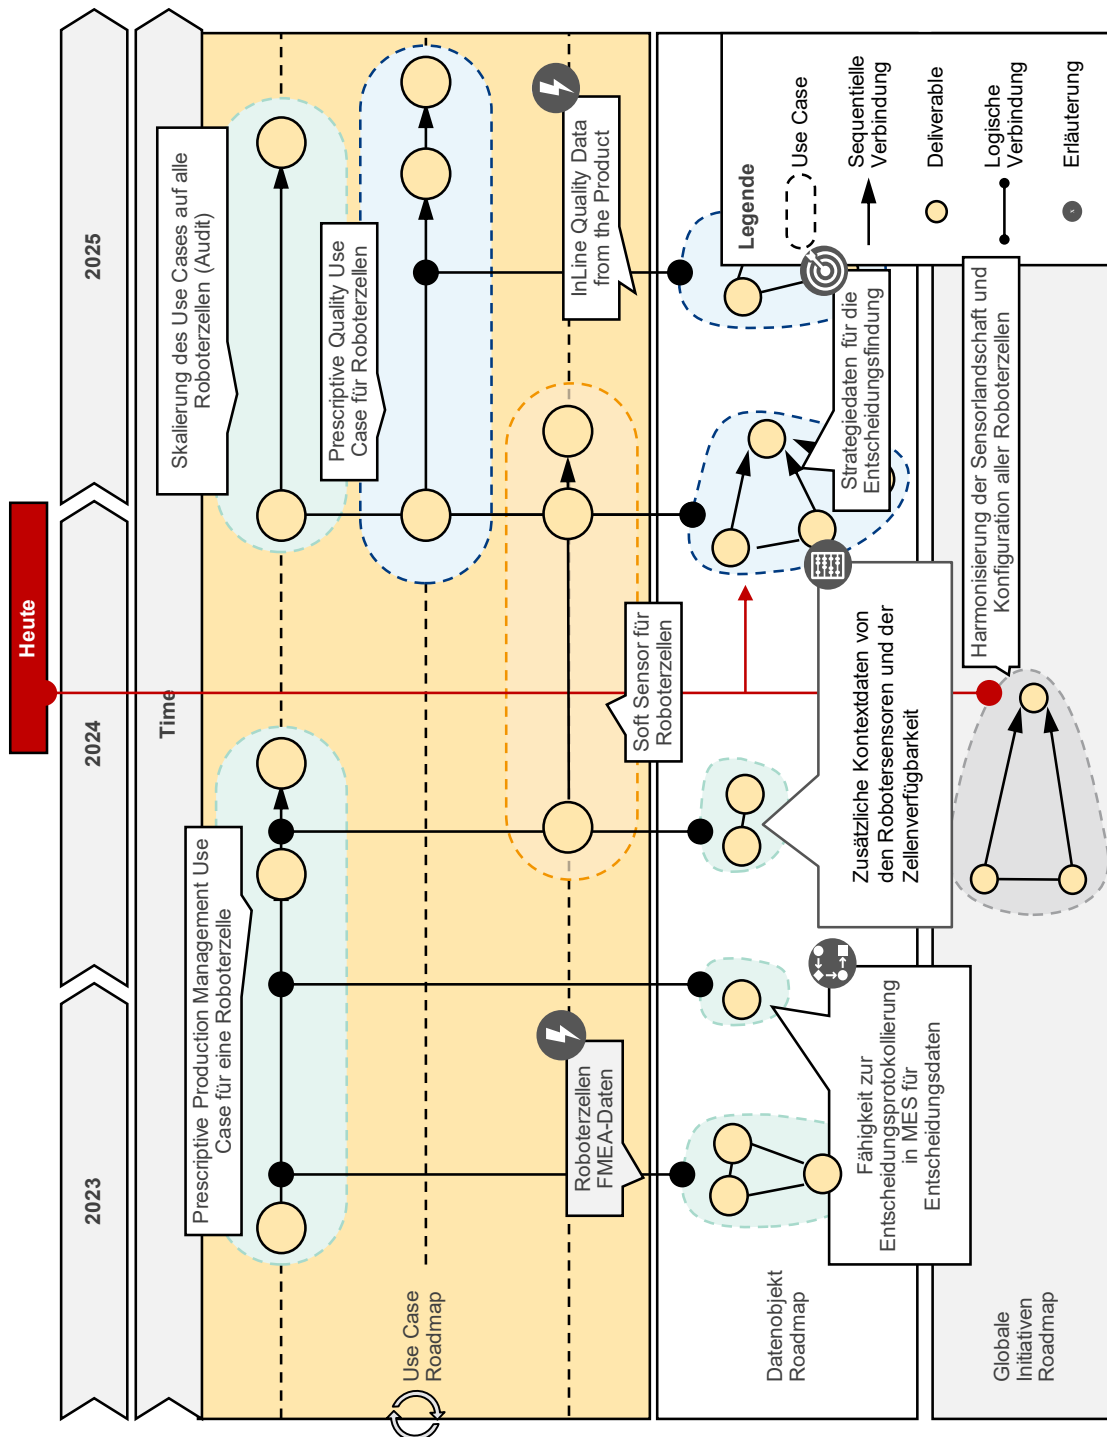


Bild A-44: Roadmap zur Umsetzung der ausgewählten Prescriptive Analytics Use Cases

## A4.9 Detaillierte Pipeline

Kern des Use Cases ist die Unterstützung bei Entscheidungen im Störfall des Produktionsablaufs. Ein Überblick über die resultierende Pipeline ist in Bild A-45 abgebildet. Hierfür müssen verschiedene Datenquellen (IoT Daten, Expertenwissen und Dokumente) herangezogen werden. Weiterhin müssen die Informationen und das Wissen aus den Quellen kombiniert und den Entscheidern zur Verfügung gestellt werden. Der Aufbau der finalen Pipeline orientiert sich an der Referenzpipeline aus Kapitel 4.5.6. Die Bausteine Intelligence, Prescription und Execution werden im Folgenden beschrieben. Ergänzend wird der Prozess des Hinzufügens neuer Expertendokumente kurz umrissen. Für weiterführende Beschreibungen wird auf [NMW+25] verwiesen. Auf der Grundlage einer Vorhersage unter Unsicherheit (Intelligence) wird eine Bewertung der präskriptiven Alternativen vorgenommen (Bewertung der Alternativen). Die Bewertung der Alternativen basiert auf dem Wissensgraphen, in dem relevantes Wissen über Produktionsentscheidungen gespeichert ist. In Schritt drei wird eine Reihe möglicher Alternativen bereitgestellt (Auswahl der Alternativen). Dies könnte beispielsweise bedeuten, dass der Greiferdruck angepasst werden sollte, um auch Objekte trotz eines verformten Greifers greifen zu können. Die Empfehlungen basieren auf dem Expertenwissen aus den verschiedenen fabrikbezogenen Expertendokumenten (z. B. FMEA, Berichte, Betriebsrichtlinien). Der resultierende Lösungsraum wird auf der Grundlage des Vorhandenseins möglicher Lösungen im Wissensgraphen bewertet. Es wird eine Handlungsempfehlung ausgewählt (Schritt drei).

Zur Abspeicherung der Entscheidungsdaten wird eine Graph-Datenbank vorgeschlagen (vgl. Use Case Architektur). Diese bieten sich besonders an aufgrund ihrer Erweiterbarkeit und Stärken bei der Analyse von Beziehungen zwischen verschiedenen Elementen an [BGM+21, RLL16, S. 6940]. Die in der Data Canvas gesammelten Datentypen werden über eine Pipeline integriert. Die relevanten Dokumente (FMEAs, Handbücher der Roboterzellen, MES-Bewegungsdaten) werden vorverarbeitet (Chunking und Segmentierung), embedded, gelabelt und maschinenlesbar abgespeichert. Die so vorliegenden Ausgangsdaten können in einen Graphen eingefügt werden. Hierbei müssen zusätzliche Schritte zur Vernetzung der einzelnen Knoten (Wissenselemente) vorgenommen werden. Die Live-Daten der IoT Factory werden über eine gesonderte Logik in den Wissensgraph integriert.

Der Block der eigentlichen „Prescription“ wird über einen Retrieval-Augmented Generation Mechanismus umgesetzt. Die Pipeline verwendet State-of-the-Art Sprachmodelle und basiert auf zwei verschiedenen Retrieval Ansätzen. Entweder wird über die Textähnlichkeit („Embeddings“) das relevante zur Entscheidung passende Kontextwissen extrahiert. Alternativ kann eine zum Datenbankschema und Frage passende Abfrage an die Datenbank via Datenbankabfragesprache gestellt werden. Existierende Antworten werden gecached. Ein sich selbst verbesserndes System kann geschaffen werden, wenn die Qualität der Antworten vom Nutzer bewertet wird. Es entsteht ein auf dem Feedback des Nutzers basierende Anpassung der Kantengewichte im Graph. Online Learning wird

durch die Dynamisierung des Wissensgraphen erzeugt. Das heißt, es können kontinuierlich weitere Dokumente oder Wissens Elemente hinzugefügt werden. Mechanismen wie Intentional Forgetting werden benötigt, um das Löschen fehlerhafter Empfehlungen aus dem Graph entfernen zu können. Alle beschriebenen Mechanismen basieren auf dem Prinzip der Bounded Rationality. Es werden nicht die mathematisch optimalen Lösungen vorgeschlagen. Stattdessen werden die bekanntesten und ähnlichsten Lösungs-Fehler paar ermittelt. Dies hat zur Folge, das mit dem vorgenommenen Pipelineaufbau nur eine schrittweise Skalierung im möglichen Automationsgrad (Abhängigkeit vom Online Learning) möglich ist.

Die anschließende Ausführung der gegebenen Handlungsempfehlung wird in erster Instanz durch den Entscheider umgesetzt. So wird bei einem anfänglich fehlenden Vertrauen in die Verlässlichkeit des Use Cases ein Sicherungsmechanismus eingebaut. Je nach gewähltem Entscheidungsparadigma (hier: dezentral [BMM+06, S. 8]) müssen die Entscheidungen im Use Case an andere Stellen kommuniziert werden.

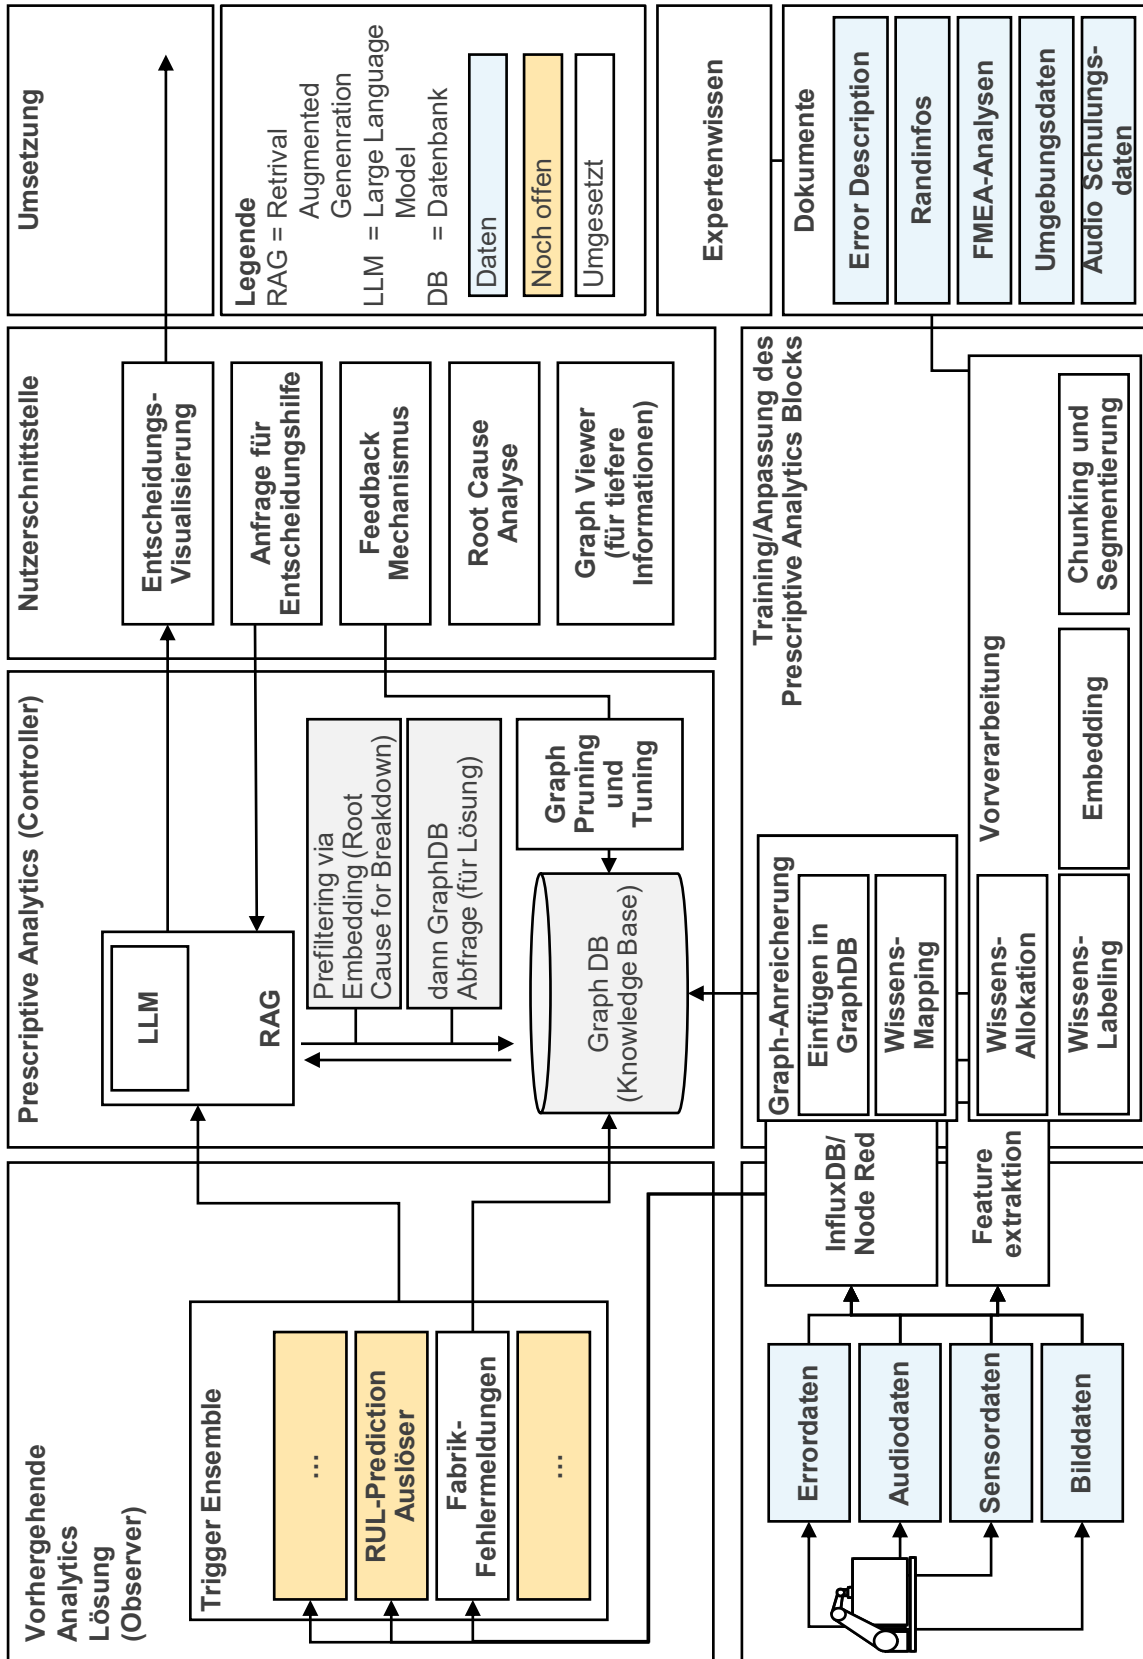


Bild A-45: Prescriptive Analytics Pipeline des Prescriptive Production Management Use Cases der IoT Factory

## A4.10 Ergebnisse der Nutzerevaluation

Das folgende Kapitel gibt einen Überblick über die Leitfragen und die Fragen für die Likert-Skala Erhebung. Tabelle A-17 fasst die gestellten Leitfragen zusammen.

*Tabelle A-17: Übersicht über die Leitfragen*

<b>Allgemeines</b>	1. In Prozent, wie gut haben Sie die Funktionsweise der Spezifikationstechnik verstanden?
	2. Was sind Ihre ersten Gedanken zur Spezifikationstechnik?
	3. Wo und wie kann die Spezifikationstechnik bei Ihnen im Unternehmen angewendet werden?
<b>Vorteile und Herausforderungen</b>	4. Welche Vorteile sehen Sie in der Anwendung der Spezifikationstechnik für das Unternehmen, in dem Sie tätig bist?
	5. Welche Herausforderungen werden trotz der Anwendung der Spezifikationstechnik bestehen bleiben?
<b>Rahmenbedingungen und Ausblick</b>	6. Inwiefern trägt die Spezifikationstechnik zur Verbesserung oder Vereinfachung der Prescriptive Analytics Use Case Entwicklung bei?
	7. Wo wünschen Sie sich noch mehr Unterstützung beziehungsweise mehr Forschung?

Die nachfolgende Tabelle A-18 ordnet die Antworten der Teilnehmer auf die Frage eins zu. Dabei gilt diese als Maß für die Eignung der Interviewteilnehmer für die Evaluation. Eine niedrige Prozentzahl bedeutet nicht zwingend, dass das Konzept der Spezifikationstechnik weniger verstanden wurde. Es gibt mehr einen Eindruck über die Bewertungspräferenzen des Interviewteilnehmers.

*Tabelle A-18: Übersicht über Antworten der Teilnehmer zu Leitfrage eins*

<b>Teilnehmer</b>	<b>In Prozent, wie gut haben Sie die Funktionsweise der Spezifikationstechnik verstanden?</b>
TN1	70%
TN2	80%
TN3	70%
TN4	60%
TN5	70%
TN6	40%

Tabelle A-19 gibt einen Überblick zu den verwendeten Fragen für die Likert-Skala Erhebung. Die Begriffe in Klammern stellen den Bezug zur ausgewählten Überkategorie nach PRAT ET AL. dar (vgl. [PCA14, S. 7]).

Auf einer Skala von 1 bis 4, wobei 1 schlecht und 4 gut ist, wie würde der Interviewteilnehmer die folgenden Aussagen über die Spezifikationstechnik bewerten:

*Tabelle A-19: Übersicht über die verwendeten Fragen für die Likert-Skala Erhebung*

Kategorie	Bewertung
<b>Übertrag in die Praxis (Environment)</b> Wie anwendbar ist die Spezifikationstechnik in ihrem Unternehmensalltag?	
<b>Beständigkeit der Ergebnisse (Evolution)</b> Wie langlebig schätzen sie die Ergebnisse ein/Halbwertszeit?	
<b>Vollständigkeit (Structure)</b> Wie umfangreich deckt die Spezifikationstechnik die existierenden Probleme ab?	
<b>Ausreichender Detailgrad der Unterstützung (Activity)</b> Wie viel Hilfe liefert die Spezifikationstechnik bei der konkreten Problemlösung?	

Dazu ergänzend werden relevante Aussagen aus den Interviews im Folgenden thematisch sortiert präsentiert (siehe Tabelle A-20).

*Tabelle A-20: Aussagen der Interviewteilnehmer zur Spezifikationstechnik*

Frage	Direkte Zitate
<b>Allgemeines</b>	
<b>2. Was sind Ihre ersten Gedanken zur Spezifikationstechnik?</b>	<p>„Ja, also im Überblick auf jeden Fall logisch. Hat auch so ein bisschen den 'Haben-will'-Effekt.“ (TN1)</p> <p>„Man muss [...] genau gucken, dass man es pragmatisch macht, dass es auch dann nicht zu wissenschaftlich in der Anwendung ist...“ (TN2)</p> <p>„Ich denke, das ist eine Standardvorgehensweise, wie man das groß strategisch ansetzen würde.“ (TN3)</p> <p>„Für kleinere Unternehmen müsste man das runterziehen.“ (TN3)</p> <p>Generell ist es halt so, über viele Elemente sind wir halt auch immer wieder gestolpert. Wir haben halt immer wieder, ja, die Frage, klar. Es ist einfach eine hohe Komplexität, wir brauchen die passenden Skills...“ (TN5)</p> <p>„Wenn deine Methoden dafür erstmal eine Hilfe sind, um da zu einem Ziel zu kommen und das leichter zu erarbeiten, dann ist das auf jeden Fall eine gute Sache.“ (TN5)</p>

Frage	Direkte Zitate
<p><b>3. Wo und wie kann die Spezifikationstechnik bei Ihnen im Unternehmen angewendet werden?</b></p>	<p>„Eigentlich könnte man doch dein Modell [...] zügig adaptieren auf unser Vorhaben“ (TN1)</p> <p>„Ich glaub man muss hier gucken, wenn man es in die Praxisanwendung bringt, dann geht das wahrscheinlich mit einem externen Partner, wenn man es sehr moderiert und sehr stark führt...“ (TN2)</p> <p>„Auch wenn wir nicht so eine enorm große IT-Infrastruktur haben, haben wir mit Sicherheit viele Use Cases und könnten das damit mal, glaube ich, vernünftig abbilden.“ (TN4)</p> <p>„Also die Komponenten, die du aufzeigst, passen an vielen Stellen.“ (TN5)</p> <p>„Ich habe immer oft das Gefühl, dass dieses mentale Bild, was wollen wir genau machen, wo wollen wir hin, was ist auch lohnend fürs Unternehmen, dass das teilweise sehr auseinander driftet. Das wäre auf jeden Fall schön, dass diese verschiedenen Sichten und in den jeweiligen Sprachen, die die Leute auch verstehen, dann das denen klarzumachen, das ist unsere Vision, das ist die Gemeinsamkeit. Da wollen wir hin.“ (TN5)</p>
<p><b>Vorteile und Herausforderungen</b></p>	
<p><b>4. Welche Vorteile sehen Sie in der Anwendung der Spezifikationstechnik für das Unternehmen, in dem Sie tätig bist?</b></p>	<p>„Da find ich halt eben auch gerade die Werkzeugunterstützung sehr interessant, ne, dass man dann halt eben sieht... Es gibt einen gewissen Ablauf, den man dann einhält, und das ist halt eben dann auch spannend zu sehen.“ (TN1)</p> <p>„Der Vorteil ist erstmal, dass es ja End-to-End gedacht ist und du jetzt nicht, was du sonst oft findest, dann hast du irgendwie 'nen tollen Ansatz für Prozessmodellierung dann hast du 'nen tollen Ansatz für die Daten und [...] erstmal einen Ansatz mit durchgängigen Templates, um das End-to-End zu bespielen...“ (TN2)</p> <p>„Methodisch finde ich das super.“ (TN3)</p> <p>„Das bringt eine gewisse Struktur rein in die Gedanken, die man überall so aufnimmt.“ (TN3)</p> <p>„Was ich richtig gut finde, dass du direkt ein Tool mitlieferst oder zumindest mal einen Vorschlag hast hier. Archi - damit hast du es gemacht. Es ist ein kostenloses Tool, funktioniert gut, denn das ist, glaube ich, wichtig für den Unternehmensalltag.“ (TN4)</p> <p>„Derzeit ist der Weg dahin ja unklar an vielen Stellen. Daher bin ich immer ein Fan von systematischem Vorgehen an der Stelle.“ (TN5)</p> <p>"Diese Strukturen können schon helfen. Auch wenn ich jetzt so ein bisschen überlege, was in Richtung dieser Business Integration IT Ebene da vor allem läuft [...]. Wie wird es gepflegt? Also so eine gewisse Strukturierung dahinter, wie das angegangen und wie es dokumentiert werden müsste, das würde Sinn ergeben." (TN6)</p>

Frage	Direkte Zitate
<p><b>5. Welche Herausforderungen werden trotz der Anwendung der Spezifikationstechnik bestehen bleiben?</b></p>	<p>„Ich finde das Thema mit der Informationsarchitektur [...] halt eben immer schwer zu verargumentieren, warum wir Budgets und Ressourcen daraufsetzen müssen. Jeder weiß, dass man es tun muss, jeder sagt, ja, ist ein wichtiges Thema.“ (TN1)</p> <p>Ich glaube, dass das auch Abschreckung erzeugen kann. [...] Dann stellen vielleicht erstmal viele fest, was sie alles nicht haben und [...] ] Wissen....“ (TN2)</p> <p>„Die Anwendung der Methode ist recht zeitraubend.“ (TN3)</p> <p>„Das Thema Management und Change-Management... wie kriege ich das Management abgeholt?“ (TN3)</p> <p>„Die Komplexität runterzuberechnen für Anwender, die da recht operativ unterwegs sind, glaube ich, ist eine Herausforderung.“ (TN4)</p> <p>„Wir haben die Spezialisten gar nicht dafür, die das alles beurteilen können.“ (TN4)</p> <p>„Ich habe immer oft das Gefühl, dass dieses mentale Bild, was wollen wir genau machen, wo wollen wir hin, was ist auch lohnend für das Unternehmen, dass das teilweise sehr auseinander driftet.“ (TN5)</p> <p>„Und wir sprechen, genau, die Durchgängigkeit auch dazwischen, das ist auch ein großes Hindernis.“ (TN5)</p> <p>"Ich glaube, das ist so ein bisschen das, wo ich die größten Probleme sehe, beziehungsweise warum auch bei uns das wahrscheinlich wenig so nach Modell gemacht wird, dass es von oben nach unten kommt, sondern es ist halt eher andersrum, dass wir halt schauen, wo sind die Möglichkeiten da, was können wir wirklich umsetzen? Und dann schauen wir, dass wir das hinkriegen." (TN6)</p> <p>"Man kann sich erstmal 'nen Use Case überlegen und dann stellt man fest, die ganzen Datengrundlagen sind einfach nicht da. Zu viel Müll in den Datenbanken stehen. Das sind halt irgendwelche Muster Use Cases, [...] aus, aber auf unserem verketteten Anlagenprozess mit zig Einflussfaktoren und so weiter. Da ist es ein bisschen die gleichen Probleme, auch warum wir jetzt nicht tausend verschiedene Predictive Maintenance und sonst wie Sachen am Laufen haben, ist weil einfach [...] es gibt eine Vielzahl von Einflussfaktoren auf den Prozess, eine Vielzahl von Dingen, die falsch laufen können in den Daten und überall, und da dann quasi den Use Case da so rausarbeiten zu können, da hakt es am Ende oft." (TN6)</p>
<p><b>Rahmenbedingungen und Ausblick</b></p>	

Frage	Direkte Zitate
<p><b>6. Inwiefern trägt die Spezifikationstechnik zur Verbesserung oder Vereinfachung der Prescriptive Analytics Use Case Entwicklung bei?</b></p>	<p>„Weil du ja deine Durchgängigkeit der Daten hast, die dann wahrscheinlich einzelne Partialmodelle abschalten wird, anschalten wird je nach Anforderungen. Stell mir das so vor wie im Systems Engineering Ansatz.“ (TN1)</p> <p>„Wenn das so ist, würde ich auf jeden Fall sagen 'very high', weil wir dann auch in der Lage wären, das Ganze einmal mit einem Initiaufwand so aufzubauen, dass man dann wahrscheinlich hinten raus den Mehrwert sich ziehen kann.“ (TN1)</p> <p>Ich glaub auch, dass die Komplexität, die man hier sieht, sehe ich schon auch als Vorteil, weil ich glaub viele unterschätzen das immer...“ (TN2)</p> <p>„Deswegen ist es glaube ich, schon ein Vorteil, dass man diese Komplexität an sich erstmal sichtbar macht und dann die Kurve kriegt zu sagen 'Aha, muss aber nicht alles auf einmal machen, sondern wir fangen jetzt erstmal an einer Stelle an und gehen dann dadurch.“ (TN2)</p> <p>„Ich glaube, dass es für den Bereich der Lösungsentwicklung für unsere Kunden sehr gut vorstellbar ist.“ (TN3)</p> <p>„So ein Rahmenwerk zu bekommen mit einem Vorgehensmodell ist, glaube ich, gar nicht so verkehrt.“ (TN3)</p> <p>„Ich glaube, dass es hilfreich ist, ein strukturiertes Vorgehen zu haben, um Use Cases zu entwickeln und zu integrieren.“ (TN5)</p> <p>„Das würde auf jeden Fall helfen, die Leute gut zu synchronisieren.“ (TN5)</p> <p>"Eine gewisse Strukturierung dahinter, wie das angegangen und wie es dokumentiert werden müsste, das würde schon Sinn ergeben ja." (TN6)</p>

Frage	Direkte Zitate
<p><b>7. Wo wünschen Sie sich noch mehr Unterstützung beziehungsweise mehr Forschung?</b></p>	<p>„Ab einem bestimmten Punkt wäre es sicherlich sinnvoll gewesen, sich mit dieser ganzen Ebene der IT-Integration schon früher zu beschäftigen. Wir haben es jetzt gemacht, aber wir sind immer noch nicht an dem Punkt, dass man jetzt so einen Datenkatalog vollständig hätte.“ (TN1)</p> <p>„Vielleicht auch noch mal ein ganz spannendes Thema - Wie man solche Modelle dann zwar kompatibel hält, aber einfach iterativ ausbaubar macht, ohne dass man jetzt irgendwie alles neu erfinden muss und Co?“ (TN2)</p> <p>„Eine Anpassung der Methode für den Mittelstand wäre hilfreich.“ (TN3)</p> <p>„Das Change-Management ist ein kritischer Faktor.“ (TN3)</p> <p>„Wäre es nicht cool, wenn du das als [...] Startup (zur Verfügung stellst), welches dass den Unternehmen als Software strukturiert zur Verfügung stellt?“ (TN4)</p> <p>„Ich glaube, dieses Thema Sprachen ist noch eine Herausforderung, [...] das Prozessmodell ist vielleicht BPMN, die Applikationsarchitektur liegt in [...], der Datenkatalog gibt es nicht, technische Architektur ist in [...], das ist ja dann noch das Fit-Gap zur Realität.“ (TN5)</p> <p>„Aber es ist auch immer die Frage, nutzen die die Tools auch richtig? Also ich habe es zur Verfügung, ich möchte es eigentlich auch nutzen, aber bin ich in der Lage, das überhaupt zu tun? Daran scheitert es [...] auch oft.“ (TN5)</p>



