

Roman Dumitrescu
Christian Koldewey (Hrsg.)

Datengestützte Produktplanung

**Mit Betriebsdaten und Data Analytics
zur faktenbasierten Planung
zukünftiger Produktgenerationen
im produzierenden Gewerbe**

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

BETREUT VOM



PTKA
Projektträger Karlsruhe
Karlsruher Institut für Technologie

HEINZ NIXDORF INSTITUT
UNIVERSITÄT PADERBORN

Fachhochschule
Südwestfalen
University of Applied Sciences



Weidmüller



westaflex

CONTACT
Software

Roman Dumitrescu
Christian Koldewey (Hrsg.)

Datengestützte Produktplanung

Mit Betriebsdaten und Data Analytics zur faktenbasierten Planung zukünftiger Produktgenerationen im produzierenden Gewerbe

Die im Rahmen dieser Veröffentlichung vorgestellten Ergebnisse entstammen dem Verbundforschungsprojekt DizRuPt. Das Projekt wurde mit Mitteln des Bundesministeriums für Bildung und Forschung (BMBF) im Programm „Innovationen für die Produktion, Dienstleistung und Arbeit von morgen“ mit den Förderkennzeichen 02P17D170 bis 02P17D178 gefördert und vom Projektträger Karlsruhe (PTKA) betreut.

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.



Bibliografische Information Der Deutschen Bibliothek

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

Band 408 der Verlagsschriftenreihe des Heinz Nixdorf Instituts

© Heinz Nixdorf Institut, Universität Paderborn – Paderborn – 2023

ISSN (Print): 2195-5239

ISSN (Online): 2365-4422

ISBN: 978-3-947647-27-9

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: Timm Fichtler

Hersteller: Hans Gieselmann Druck und
Medienhaus GmbH & Co. KG
Ackerstr. 54
33649 Bielefeld

Printed in Germany

Vorwort

Unter dem Schlagwort der digitalen Transformation wird die Durchdringung aller Lebensbereiche mit Informations- und Kommunikationstechnologien verstanden. Sie wirkt als Treiber neuer Geschäfts- und Wertschöpfungspotentiale und gleichsam als Lösungsbaustein zur Bewältigung globaler Zukunftsthemen, wie Mobilität oder Kreislaufwirtschaft. Zukünftige Systeme werden folglich einen hohen Anteil digitaler Funktionen aufweisen.

Es ist offensichtlich, dass derartige Systeme nicht mit den fachdisziplin-spezifischen Methoden des klassischen Engineerings geplant, entwickelt und an den Markt gebracht werden können. Vielmehr muss auch der gesamte Produktentstehungsprozess unter dem Paradigma der Digitalisierung neu gedacht werden. Besonders die zunehmende Verfügbarkeit von Daten eröffnet hier das Potential für ein datengetriebenes Engineering. Beispiele für solche Daten sind z. B. Betriebs-, Verkaufs- oder Marktdaten. Das datengetriebene Engineering darf sich dabei nicht nur auf die Entwicklung der Systeme (Data-driven Systems Engineering) begrenzen, sondern muss auch die Gestaltung der Geschäfts- und Unternehmensorganisation miteinschließen (Data-driven Business Engineering). Nur so kann sichergestellt werden, dass Datensilos vermieden und die Potentiale moderner Datenanalyse-Technologien erschlossen werden können.

Mit Advanced Systems Engineering bildet sich ein Engineering-Ansatz heraus, der diese Herausforderungen adressiert. Er erlaubt es, interdisziplinäre Systeme modellbasiert zu gestalten, deren Entstehungsprozesse ein hohes Maß an Agilität, Kreativität und Sozialkompetenz fordern. Das vorliegende Projekt liefert einen wertvollen Beitrag zu diesem Engineering-Paradigma und zeigt dessen Nutzenpotentiale eindrucksvoll auf.

Im Fokus des Projekts DizRuPt stehen die Daten, die im Zusammenhang mit dem Betrieb bzw. der Nutzung von vernetzten Systemen entstehen. Sie können vom Hersteller analysiert werden, um die nächsten Generationen des Systems noch besser auf den Kunden auszurichten. Damit adressiert das Projekt die strategische Planung der Systeme von morgen und erlaubt es Unternehmen, frühzeitig fundierte produktstrategische Entscheidungen zu treffen. Resultat des Projekts ist ein Instrumentarium, das Unternehmen befähigt die datengestützte Produktplanung unter technologischen, organisatorischen und menschlichen Gesichtspunkten umzusetzen.

Das Instrumentarium entstand unter reger Mitwirkung unserer Industriepartner. Ohne sie wäre es nicht möglich gewesen, ein derart praxisorientiertes und nutzenstiftendes Instrumentarium zu entwickeln. Vielen Dank! Ferner danken wir dem BMBF und den Betreuern des PTKA für die Unterstützung unserer Arbeit und die professionelle Begleitung des Projekts. Es ist ein Privileg bei der Erstellung eines solchen Buchs auf zahlreiche Unterstützer zurückgreifen zu können. Wir danken allen Autoren für ihre hervorragende und engagierte Arbeit.

Ihnen, liebe Leserinnen und Leser, wünschen wir eine erkenntnisreiche Lektüre mit vielen Impulsen für Ihre tägliche Arbeit.

Paderborn, November 2022

*Prof. Dr.-Ing. Roman Dumitrescu
Dr.-Ing. Christian Koldewey*

Geleitwort des Projektträgers

Im Zuge von Industrie 4.0 bieten Unternehmen ihren Kunden zunehmend sogenannte Cyberphysische Systeme (CPS) an. Unter CPS können digitalisierte, mit Sensorik, Aktorik, Datenverarbeitung und Konnektivität ausgestattete Produkte verstanden werden, deren Komponenten einen kontinuierlichen Datenstrom erzeugen. Die Analyse der Produktdaten eröffnet den Anbietern von CPS völlig neue Einblicke in die Kundennutzung ihrer Produkte. Diese Erkenntnisse lassen sich für die strategische Planung neuartiger Produktgenerationen nutzen und bewerten. So können die Daten beispielsweise aufzeigen, dass Komponenten die an sie gestellten Anforderungen im Betrieb nicht erfüllen und verbessert werden müssen. Dies kann sowohl in zukünftigen Produktgenerationen als auch in den Bestandsmaschinen im Feld geschehen. Solch ein Ansatz stellt jedoch insbesondere KMU aufgrund fehlender Kenntnisse und Erfahrungen vor große Herausforderungen.

Ziel des Forschungsprojektes DizRuPt war deshalb die Entwicklung eines Instrumentariums, das insbesondere für KMU Methoden und Werkzeuge erarbeitet, die eine datengestützte Retrofit- und Generationenplanung ermöglichen. Das Instrumentarium wurde in vier Unternehmen validiert, die ihre Produkte datengestützt weiterentwickeln und bestehende Produkte im Markt nachrüsten. Ein weiteres Unternehmen, das auf das datenbasierte Engineering (PLM-System und IoT-Plattform) spezialisiert ist, unterstützte die Anwender bei der Umsetzung und Integration der Methoden und Werkzeuge in die Organisation.

Den Kern der Arbeiten stellt ein neuartiger Referenzprozess dar. In diesem werden zu Beginn sogenannte Produkthypothesen – planungsrelevante Annahmen über die Produktnutzung und das Betriebsverhalten – und offene Fragen zur Nutzungsphase der Produkte ermittelt. Anschließend werden Datenanalyseverfahren geplant und eingesetzt, um die Hypothesen und Fragen zu untersuchen und eventuell neue Fragen aufzustellen. Die so gewonnenen Erkenntnisse werden hierbei genutzt, um bestehende Funktionen zu hinterfragen und zukünftig relevante Eigenschaften der Produkte zu ermitteln. Diese werden strategisch in künftige Produktgenerationen eingeplant und gegebenenfalls über Retrofitting-Maßnahmen in bestehenden Produkten nachgerüstet. Um diese Vorgehensweise in den Unternehmen zu verankern, wurden neben dem Referenzprozess auch die benötigten Kompetenzen erforscht. Die parallel erarbeiteten IT-Werkzeuge umfassen die Datenakquise, -exploration und -analyse, verbesserte PLM-Funktionen zur Generationen- und Retrofitplanung sowie die Ankopplung an die IoT-Plattform.

Bereits während der Projektlaufzeit wurde das Instrumentarium, bestehend aus Leitfäden und prototypischen IT-Werkzeugen, frühzeitig über Multiplikatoren bekannt gemacht. Damit kann zukünftig beispielsweise die Nachrüstung von Bestandsanlagen mit verbesserter Sensorik effizient gestaltet werden. Dies wurde durch einen Begleit- und Transferkreis flankiert. Ergänzend wurden Schulungen angeboten. Anwendung finden die Ergebnisse im Maschinenbau und der Elektronikproduktion.

Die Partner in diesem Verbundprojekt wurden im Programm „Innovationen für die Produktion, Dienstleistung und Arbeit von morgen“ des Bundesministeriums für Bildung und Forschung (BMBF) gefördert. Allen sei an dieser Stelle gedankt, die mit ihrem Wissen, Engagement und

ihren Erfahrungen an dieser richtungsweisenden Forschungs- und Entwicklungsarbeit mitgewirkt haben.

Projektträger Karlsruhe (PTKA)
Produktion, Dienstleistung und Arbeit
Karlsruher Institut für Technologie (KIT)

Karlsruhe, Dezember 2022

Stefan Scherr



BETREUT VOM



Datengestützte Produktplanung

Inhaltsverzeichnis

1	Einführung	1
	<i>Christian Koldewey, Roman Dumitrescu, Maurice Meyer</i>	
	Literatur zu Kapitel 1	8
2	Produktplanung auf Basis von Betriebsdaten	11
	<i>Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler</i>	
2.1	Grundlegende Konzepte	11
2.1.1	Strategische Produktplanung.....	11
2.1.2	Betriebsdaten	13
2.1.3	Data Analytics.....	15
2.2	Grundidee der Betriebsdaten-gestützten Produktplanung.....	17
2.3	Chancen und Herausforderungen der Betriebsdaten-gestützten Produktplanung	21
	Literatur zu Kapitel 2	24
3	Referenzprozess für die Betriebsdaten-gestützte Produktplanung	29
	<i>Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler, Daniel Panick</i>	
3.1	Planung von Betriebsdaten-Analysen	30
3.1.1	Analytics-Bedarfsanalyse	31
3.1.2	Analytics-Potentialanalyse.....	34
3.1.3	Use-Case-Entwurf	36
3.1.4	Use-Case-Konkretisierung.....	39
3.2	Vorbereitung von Betriebsdaten-Analysen	40
3.2.1	Analytics-Spezifikation.....	42
3.2.2	Zielatendefinition.....	45
3.2.3	Datensammlung.....	47
3.2.4	Datenbeschreibung.....	49

3.3	Durchführung von Betriebsdaten-Analysen	53
3.3.1	Analytics-Workflow-Entwurf	55
3.3.2	Datenvorverarbeitung	58
3.3.3	Modellierung	61
3.3.4	Modell-Evaluation	63
3.4	Verwertung von Betriebsdaten-Analysen.....	65
3.4.1	Ergebnis-Interpretation	66
3.4.2	Zielsystem-Überarbeitung.....	68
3.4.3	Ideenfindung	70
3.4.4	Umsetzungsplanung.....	72
	Literatur zu Kapitel 3.....	75
4	Effiziente Umsetzung in Unternehmen	78
	<i>Ingrid Wiederkehr, Lukas Isenberg, Maurice Meyer</i>	
4.1	Rollen im Kontext der Betriebsdaten-gestützten Produktplanung .	78
4.2	Kompetenzen für die Betriebsdaten-gestützte Produktplanung	80
4.3	Organisatorische Verortung	82
4.4	Incentivierung der Kunden für die Datenbereitstellung	84
	Literatur zu Kapitel 4.....	86
5	IT-Unterstützung	89
	<i>Thomas Dickopf, Christo Apostolov, Ian Altmann, Andreas Saum</i>	
5.1	Werkzeugseitige Unterstützung des Referenzprozesses	89
5.2	Datendurchgängigkeit entlang des Closed-Loop-Engineering-Ansatzes	93
5.2.1	Identifizierung und Lokalisierung des Bedarfs an Produktuntersuchungen.....	93
5.2.2	Ableitung und Erstellung des digitalen Zwillings aus der PLM- Produktstruktur	94
5.2.3	Erfassung, Verwendung und Analyse von Daten und Ableitung von Erkenntnissen	97
5.2.4	Retrofit-Generierungsplanung auf Basis von Erkenntnissen und bewerteten Hypothesen.....	99
5.2.5	Datenmodell des Closed-Loop-Engineering-Ansatzes für die Betriebsdaten-gestützte Produktplanung.....	101

6	Einblicke in die Anwendungsbeispiele des Forschungsprojekts „DizRuPt“	103
	<i>Moritz Schilling, Daniel Panick, Ingo Kaiser, Thomas Dickopf, Stefan Wecker, Olaf Knospe</i>	
6.1	Anwendungsbeispiel 1: LASCO Umformtechnik GmbH	103
6.1.1	Nachrüstung von MEMS-Sensoren zur Messung von Beschleunigungen am Gestell eines Oberdruckhammers	104
6.1.2	Einbinden eines Oberdruckhammers an das Internet der Dinge	109
6.2	Anwendungsbeispiel 2: Weidmüller Interface GmbH & Co. KG	113
6.2.1	Analyse von Log-Files am Beispiel eines Remote I/O-Systems	114
6.2.2	Rückführung der Analyse-Erkenntnisse in das Requirements-Management-System.....	117
6.3	Anwendungsbeispiel 3: Diebold Nixdorf Systems GmbH.....	120
6.3.1	Datenakquise an einem Geldautomaten (geschlossenes System) durch eine intelligente Steckdose	121
6.3.2	Aufbau von Microservices und datenbasierten Geschäftsmodellen...	124
6.4	Anwendungsbeispiel 4: Westaflexwerk GmbH	127
6.4.1	Nachrüstung von Beschleunigungssensoren am Gehäuse eines Lüftungsgeräts.....	128
6.4.2	Analyse von Unwuchten in einem Lüftungsgerät.....	132
	Literatur zu Kapitel 6.....	136
7	Tipps für den Transfer in die Praxis.....	137
	<i>Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler</i>	
8	Resümee und Ausblick	139
	<i>Christian Koldewey, Roman Dumitrescu, Maurice Meyer</i>	
	Abkürzungsverzeichnis	141
	Autorenverzeichnis	143
	Vorveröffentlichungen	149

1 Einführung

Christian Koldewey, Roman Dumitrescu, Maurice Meyer

Vor etwas mehr als 10 Jahren wurde die vierte industrielle Revolution – **Industrie 4.0** – ausgerufen [KLW11]. Bis heute hat sie nichts von ihrer initialen Dynamik verloren. Dies liegt zum einen an den gewaltigen technologischen Potentialen und den aus ihnen folgenden Effizienz- und Wettbewerbsvorteilen. Auf der anderen Seite ist die Digitalisierung für viele Unternehmen unausweichlich, um die Herausforderungen in der globalen Wettbewerbsarena zu meistern, wie z. B. den Klimaschutz oder die Resilienz der Lieferketten.

Der Grundgedanke von Industrie 4.0 ist die wertschöpfende Nutzung der Daten aus Produkten, Prozessen und Systemen. Basis dafür sind sog. **cyber-physische Systeme** (CPS), welche die Daten der physischen Welt mit Sensoren erfassen, sie in Netzwerken verfügbar machen und durch Aktoren unmittelbar auf Prozesse der physischen Welt einwirken [GB12]. Es entsteht ein Internet der Dinge und Dienste, in denen die CPS interagieren und ihre Fähigkeiten als Dienste anbieten. Um dabei die digitale Souveränität sicherzustellen, rücken Datenraumkonzepte (z. B. GAIA-X) verstärkt in den Fokus. In Datenräumen interagieren vertrauenswürdige Partner anhand gemeinsamer Standards und Richtlinien zu Datenaustausch und -speicherung in sich überlappenden Ökosystemen [Gai23-ol]. Der resultierende zunehmende Datenreichtum auf Basis von CPS bietet faszinierende Perspektiven, insbesondere wenn moderne Datenanalyseverfahren eingesetzt werden.

Bild 1-1 zeigt diese Zusammenhänge schematisch auf. Im Zentrum der Betrachtung produzierender Unternehmen steht dabei das eigene Produkt – also in der Regel ein CPS. Typische CPS sind Produktionsanlagen, Industrieroboter oder auch moderne Automobile. Wir betrachten im Folgenden insbesondere Business-to-Business (B2B) Produkte, die in Unternehmen eingesetzt werden. Sie stellen also gemäß des Systemdenkens das System-of-Interest dar [ISO42010]. Im Kern steht dabei ein mechatronisches System bestehend aus Grundsystem, Sensorik, Aktorik und Informationsverarbeitung. Die Sensoren erfassen den Zustand des mechanischen Grundsystems und dessen Umgebung und leiten diese Größen an die Informationsverarbeitung weiter. Diese berechnet daraus der Programmierung folgend die Stellsignale für die Aktorik, welche wiederum auf das Grundsystem einwirkt [GDE+19], [VDI2206]. Werden diese Systeme mit Kommunikationssystemen ausgestattet und befähigt, über Netzwerke Daten und Dienste auszutauschen und zu nutzen, wird von cyber-physischen Systemen gesprochen [Lee08], [Bro10]. Ferner verfügen CPS meist über multimodale Mensch-Maschine-Schnittstellen [KWH13], [GB12].

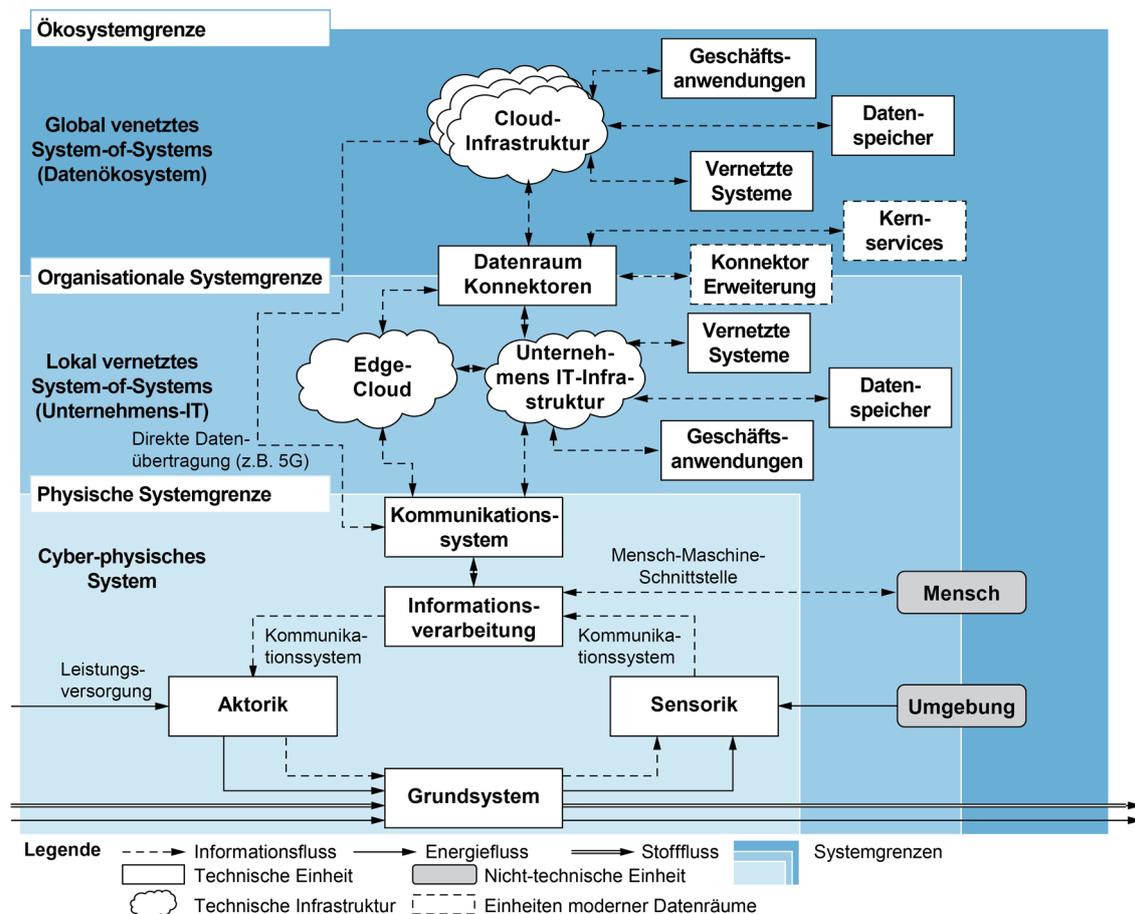


Bild 1-1: Grundstruktur von vernetzten intelligenten Systemen – cyber-physische Systeme [GDE+19]

CPS, die in Unternehmen eingesetzt werden, sind in der Regel zunächst mit dessen **IT-Infrastruktur** vernetzt. Über diese kommunizieren sie mit weiteren vernetzten Systemen, also anderen CPS. Sie greifen auf Datenspeicher zu, liefern und lesen Daten. Ferner interagieren sie mit Geschäftsanwendungen (Diensten), wie PLM-, ERP- oder MES-Systemen. Mit dem Überschreiten der **physischen Systemgrenze** verortet sich das CPS folglich zunächst in einem lokal vernetzten System-of-Systems – der Unternehmens-IT. System-of-Systems (SoS) stellen dabei übergeordnete Systeme dar, die sich aus unabhängigen Systemen zusammensetzen, welche (1) jeweils ihren eigenen Zweck erfüllen – auch wenn sie aus dem SoS herausgelöst werden – und (2) für diesen eigenen Zweck (zumindest in Teilen) gemanagt werden – im Gegensatz zum Zweck des SoS [Mai98]. Ein vernetztes Fertigungssystem besteht beispielsweise aus den CPS diverser Hersteller wie Werkzeugmaschinen (vernetzte Systeme) sowie unterschiedlichsten Software-Tools wie MES-Systemen (Geschäftsanwendungen) und Datenbanken. Die Systeme tauschen dabei über eine Infrastruktur ihre Daten aus.

Eine Alternative zur direkten Vernetzung mit der IT-Infrastruktur stellt die Nutzung von sog. **Edge-Clouds** dar. Dabei handelt es sich um lokale Recheninstanzen am Rand des Netzwerks, die als Schnittstelle zwischen CPS und Cloud oder IT-Infrastruktur fungieren.

Sie eignen sich besonders, um zeitkritische Funktionen der Datenanalyse zu realisieren oder besonders vertrauliche Daten zu verarbeiten [PM18].

Darüber hinaus können CPS auch **direkt an die Cloud** angebunden werden. In diesem Fall wird das Kommunikationssystem des CPS so ausgelegt, dass es eine mobile bzw. direkte Internetverbindung aufbauen kann (z. B. 5G, WLAN und Router). Diese Art der Vernetzung wird beispielsweise bei Lastwagen genutzt.

Mit der Vernetzung in die Cloud wird die **organisationale Systemgrenze** überschritten und es resultiert ein global vernetztes System-of-Systems – ein Datenökosystem. In Datenökosystemen teilen verschiedene Akteure Daten zur gemeinschaftlichen Wertschöpfung [AMM+20], [OL18]. Derzeit bilden sich Datenraumkonzepte als Lösung zur Realisierung dieser Ökosysteme heraus. Sie schaffen einen Standard, welcher den Datenaustausch zwischen den Akteuren deutlich vereinfacht. Im Zentrum stehen sog. Datenraum-Konnektoren. Sie stellen ein Framework für einen souveränen Datenaustausch zwischen Organisationen bereit und erlauben in der Regel Datenabfrage, Datenaustausch, Richtliniendurchsetzung, Überwachung und Auditierung. Über die Konnektoren werden die Clouds der Akteure vernetzt. Dies ermöglicht den Zugriff auf Daten, Geschäftsanwendungen und vernetzte Systeme. Moderne Datenräume wie CATENA-X stellen ferner verschiedene Kernservices bereit, die Basisfunktionen wie Identitätsservices realisieren. Ferner liefern sie Erweiterungen für die Konnektoren, z. B. API Wrapper [Cat22].

Die Hersteller der CPS können in dieser Architektur eine Anbindung zu ihrer IoT-Plattform bzw. Cloud realisieren. Damit werden die Betriebsdaten der Produkte für sie in zunehmendem Ausmaß zugänglich. Hieraus resultieren zahlreiche Potentiale: Sie können neue datenbasierte Marktleistungen anbieten wie z. B. Smart Services [KGD+21] oder sie können die Daten nutzen, um ihre eigene Wertschöpfung rund um das Produkt zu optimieren [GWE+17]. Im Fokus des vorliegenden Buchs steht Zweiteres. Genauer: Wir werden zeigen, wie die Betriebsdaten von CPS genutzt werden können, um Letztere strategisch weiterzuentwickeln. Dies erfolgt im Rahmen der **Produktentstehung** (s. Bild 1-2). Sie bezeichnet den Prozess von der ersten Idee bis zum Serienanlauf. Die Produktentstehung kann nach GAUSEMEIER als ein Wechselspiel von vier Zyklen und ihrer Hauptaufgaben verstanden werden [GDE+19]: Der erste Zyklus befasst sich mit der Strategischen Produktplanung und umfasst den Planungsprozess von der initialen Potentialfindung bis zum Erfolg versprechenden Entwicklungsauftrag. Die Produktentwicklung stellt den zweiten Zyklus dar und befasst sich mit der fachübergreifenden Produktkonzipierung, dem Entwurf und der Integration der Teillösungen. Dienstleistungen werden im dritten Zyklus entwickelt. Hier erfolgen die Konzipierung, Planung und Integration des Dienstleistungsangebots. Im vierten Zyklus werden die Produktionssysteme entwickelt, d. h. sie werden konzipiert, die Arbeitsplanung wird vorgenommen und die Teillösungen werden integriert.

In der strategischen Produktplanung werden die Weichen für die zukünftigen Produkte gestellt; hier können Erkenntnisse aus der Analyse der Betriebsdaten besonders großen

in der Entwicklungsorganisation erforderlich (**Mensch**). Hier kann es z. B. notwendig sein, dass Entwicklungsingenieure in Zukunft auch in der Dateninterpretation mitwirken. Es resultiert folglich ein komplexer Gestaltungsraum für die datengestützte Produktplanung, der vier Bestandteile und drei Sichten integriert. Bild 1-3 zeigt dies.

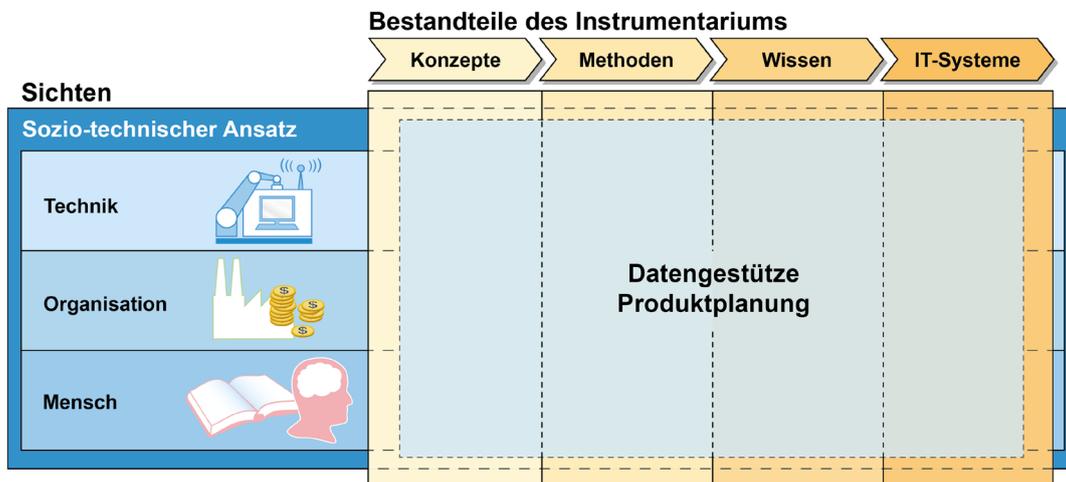


Bild 1-3: Gestaltungsraum der datenbasierten Produktplanung

Forschungsansatz

Der Forschungsgegenstand umfasst ein Thema, welches sich durch einen hohen Praxisbezug auszeichnet. Um das Forschungsziel zu erreichen, ist folglich eine intensive Zusammenarbeit von Wissenschaft und Praxis erforderlich. Dies wird durch den Forschungsansatz der Konsortialforschung ermöglicht. Dieser Ansatz zeichnet sich durch einige vorteilhafte Eigenschaften aus [ÖO10]:

- Forscher und Praktiker definieren gemeinsam die Forschungsziele, besprechen das Vorgehen und evaluieren die Resultate.
- Die Unternehmen gewähren den Forschern umfassenden Einblick in und Zugriff auf ihr Wissen.
- Projektergebnisse (Artefakte) lösen praktische Probleme.
- Es finden zahlreiche Iterationen über mehrere Unternehmen hinweg statt.
- Die Unternehmen validieren die Resultate in ihrem Geschäft.
- Forscher und Praktiker arbeiten über einen definierten langfristigen Zeitraum zusammen.

Konsortialforschung erfolgt in vier Phasen: Analyse, Gestaltung, Evaluation und Diffusion. Bild 1-4 zeigt die Ausprägung der Konsortialforschung für das Projekt. Nachfolgend werden die Phasen kurz erläutert [ÖO10]:

Die **Analyse-Phase** reicht von der ersten Projektidee bis zum ausgearbeiteten Forschungsrahmenplan. Dabei werden die Problematik und der Stand der Technik analysiert, um Forschungslücken und -ziele zu definieren.

In der **Design-Phase** werden die Projektergebnisse in Form von Artefakten (Konstrukte, Theorien, Modelle, Methoden oder Instanziierungen) erarbeitet. Wesentlich ist hier die iterative Entwicklung mit den Praxispartnern, um die Relevanz und Nützlichkeit der Resultate zu sichern. Dabei werden etablierte Forschungsmethoden wie Design Science eingesetzt.

Die **Evaluations-Phase** dient der Feststellung, ob die Resultate die Projektziele erreichen, d. h. ob sie anwendbar sind und den erwarteten Nutzen liefern. Hier werden u. a. Review-Workshops mit den Praxispartnern durchgeführt sowie die Artefakte in Pilotanwendungen bei den Unternehmen eingesetzt.

Abschließend folgt die **Diffusions-Phase**. Sie dient der Kommunikation der Resultate in die Öffentlichkeit. Es werden sowohl wissenschaftliche als auch populärwissenschaftliche Publikationen erstellt. Ferner erfolgt der Transfer in die Lehre sowie die Umsetzungsplanung in den Unternehmen.

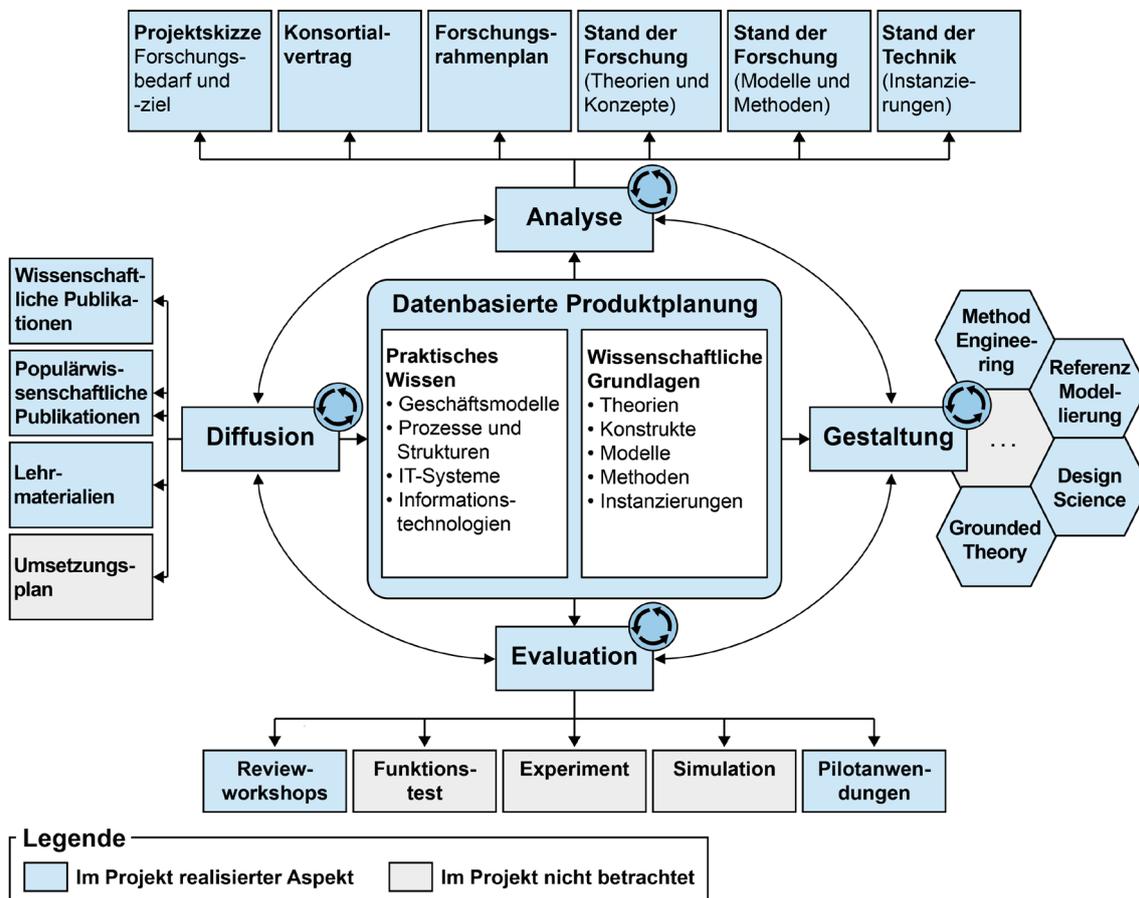


Bild 1-4: Realisierung des Konsortialforschungsansatzes im Projekt in Anlehnung an ÖSTERLE und OTTO [ÖO10]

Bei der Konsortialforschung handelt sich jedoch um keine stringente Abfolge an Phasen, sondern um ein iteratives Vorgehen: Analyse, Gestaltung, Evaluation und Diffusion wechseln sich ab.

Das Konsortium selbst setzt sich aus acht Partnern zusammen: drei Forschungseinrichtungen, einem Befähigerunternehmen und vier Anwenderunternehmen. Ferner sind weitere Unternehmen und Multiplikatoren (Verbände, Verbände, etc.) mit dem Projekt assoziiert. Sie dienen dem Breitentransfer. Bild 1-5 zeigt die realisierte Innovationskette.



Bild 1-5: Innovationskette des Konsortialprojekts DizRuPt

Die Fachgruppe **Advanced Systems Engineering (ASE)** des Heinz Nixdorf Instituts der Universität Paderborn von Professor Dumitrescu befasst sich mit dem Engineering im Kontext der Digitalisierung. Schwerpunkte bilden das Business Engineering und das Systems Engineering. Damit verfügt die Fachgruppe über umfassende Kompetenzen in den Themen strategische Produkt- und Unternehmensgestaltung sowie Entwicklungsmethodik für cyber-physische Systeme.

Das **Institut für Werkzeugmaschinen und Fabrikbetrieb (IWF)** der Technischen Universität Berlin entwickelt wissenschaftliche Grundlagen zu Prozesstechnologien, Produktionsanlagen und informationstechnischen Modellen im Kontext des industriellen Fabrikbetriebs. Des Weiteren befasst sich das Produktionstechnische Zentrum (PTZ) in Berlin seit mehreren Jahren mit der Thematik Retrofit, insbesondere auch im Zusammenhang mit Industrie 4.0.

Das **Labor für Massivumformung (LFM)** der Fachhochschule Südwestfalen untersucht technische und organisatorische Fragestellungen produzierender Unternehmen im Bereich umformender Fertigungsverfahren und insbesondere in der Schmiedetechnik und Kaltumformung. Dies umfasst die Auslegung von Bauteilen, die Werkzeuggestaltung und Prozessauslegung bis hin zur Maschinenkonstruktion. Besonders die digitale Transformation der Unternehmen wird dabei berücksichtigt.

Die **CONTACT Software GmbH (CONTACT)** ist einer der führenden Anbieter von Software für die Produktentstehung und die digitale Transformation. Das Leistungsangebot umfasst dabei sowohl das PLM-System CIM Database PLM als auch die Digital-Twin-Plattform Elements for IoT. Die Software-Lösungen sind modular aufgebaut und erlauben es, den gesamten Produktlebenszyklus abzubilden – von der ersten Idee bis zum Einsatz der Produkte beim Kunden.

Die **Weidmüller Interface GmbH & Co. KG (Weidmüller)** befasst sich schwerpunktmäßig mit der elektrischen Verbindungstechnik und Elektronik. Im Bereich Industrie 4.0 und Digitalisierung ist das Unternehmen Wegbereiter für seine Kunden und liefert konkrete Lösungen. Daneben verfügt das Unternehmen über weitreichende Kompetenzen im Bereich Industrial Data Analytics. Fokus ist die Überwachung und Prädiktion des Zustandes von Maschinen und Anlagen.

Die **LASCO Umformtechnik GmbH (Lasco)** ist Lieferant von Maschinen und Anlagen für umformende Fertigungsverfahren. Das Unternehmen war bereits in den 1990er Jahren Pionier in der Automatisierung von Hammeranlagen für die Warmmassivumformung. Bereits damals hat Lasco ein erstes, auf handgehaltenen Kamerasystemen, externen Monitoren und der Bündelung mehrerer ISDN-Leitungen basierendes Fernwartungssystem für seine Kunden bereitgestellt. Mittlerweile wurde die Fernwartung stark ausgebaut und auch mit digitalen Zwillingen der Anlagen verbunden.

Die **Diebold Nixdorf Systems GmbH (Diebold Nixdorf)** ist weltweit führender Anbieter von IT-Lösungen und -Services für Retailbanken und Handelsunternehmen. Der Standort Paderborn ist der Hauptstandort der Diebold Nixdorf Systems GmbH. Hier ist der Großteil der Forschung und Entwicklung beheimatet und darüber hinaus stellt der Standort den wichtigsten und größten Produktionsstandort im Gesamtunternehmen.

Die **Westaflexwerk GmbH (westaflex)** verfügt über weitreichende Kompetenzen in der Entwicklung von Lüftungsgeräten. Die Entwicklung der Lüftungsgeräte wird durch westaflex vornehmlich in Eigenregie durchgeführt. Dabei werden alle technischen Disziplinen von der Mechanik über die Elektrotechnik/Software bis hin zu den Produkttests im Unternehmen abgebildet.

Im weiteren Verlauf des Buchs werden die Resultate des Verbundforschungsprojekts vorgestellt. In Kapitel 2 werden die theoretischen Grundlagen diskutiert sowie Chancen und Herausforderungen vorgestellt. Kapitel 3 führt den Referenzprozess für die Betriebsdaten-gestützte Produktplanung ein. Er umfasst die vier Hauptprozesse Planung, Vorbereitung, Durchführung und Verwertung von Betriebsdaten-Analysen. Sie werden detailliert beschrieben. Die Umsetzung im Unternehmen wird in Kapitel 4 thematisiert. Dies umfasst Rollen, Kompetenzen, Organisationsstrukturen und Anreizsysteme. Kapitel 5 zeigt, wie IT-Systeme die Betriebsdaten-gestützten Produktplanung unterstützen. Die Anwendung in der Praxis wird in Kapitel 6 demonstriert. Aus den Pilotanwendungen wurden Tipps für den Transfer in die Praxis abgeleitet, die in Kapitel 7 vorgestellt werden. Das Buch schließt mit einem Resümee und Ausblick in Kapitel 8.

Literatur zu Kapitel 1

- [AMM+20] AZKAN, C.; MÖLLER, F.; MEISEL, L.; OTTO, B.: Service Dominant Logic Perspective on Data Ecosystems - A Case Study based Morphology: Proceedings of the 28th European Conference on Information Systems (ECIS). 8th European Conference on Information Systems (ECIS), 15-17 Juni, 2020

- [Bro10] BROY, M.: Cyber-Physical Systems – Innovation durch Software-intensive eingebettete Systeme. acatech DISKUTIERT, Springer-Verlag, Berlin Heidelberg, 2010
- [Cat22] CATENA-X AUTOMOTIVE NETWORK E.V. (Hrsg.): Catena-X Operating Model Whitepaper – Release V2 - 21.11.2022, 2022
- [Gai23-ol] GAIA-X EUROPEAN ASSOCIATION FOR DATA AND CLOUD AISBL: Data spaces – What are they. Unter: <https://gaia-x.eu/what-is-gaia-x/deliverables/data-spaces/>, 8. Februar 2023
- [GB12] GEISBERGER, E.; BROY, M.: agendaCPS – Integrierte Forschungsagenda Cyber-Physical Systems. Springer Vieweg, Berlin Heidelberg, 2012
- [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. Carl Hanser Verlag, München, 2019
- [GWE+17] GAUSEMEIER, J.; WIESEKE, J.; ECHTERHOFF, B.; KOLDEWEY, C.; MITTAG, T.; SCHNEIDER, M.; ISENBERG, L.: Mit Industrie 4.0 zum Unternehmenserfolg – Integrative Planung von Geschäftsmodellen und Wertschöpfungssystemen. Heinz Nixdorf Institut, Paderborn, 2017
- [ISO42010] Systems and software engineering — Architecture description, 2011
- [KGD+21] KOLDEWEY, C.; GAUSEMEIER, J.; DUMITRESCU, R.; EVERS, H. H.; FRANK, M.; REINHOLD, J.: Development Process for Smart Service Strategies: Grasping the Potentials of Digitalization for Servitization. In: Schallmo, D.; Tidd, J. (Eds.): Digitalization – Approaches, case studies, and tools for strategy, transformation and implementation. Springer eBook Collection, Springer, Cham, 2021, S. 205–237
- [KLW11] KAGERMANN, H.; LUKAS, W.-D.; WAHLSTER, W.: Industrie 4.0 – Mit dem Internet der Dinge auf dem Weg zur 4. industriellen Revolution. VDI Nachrichten, S. 2
- [KWH13] KAGERMANN, H.; WAHLSTER, W.; HELBIG, J.: Umsetzungsempfehlungen für das Zukunftsprojekt Industrie 4.0 – Abschlussbericht des Arbeitskreises Industrie 4.0. Berlin, 2013
- [Lee08] LEE, E. A.: Cyber Physical Systems – Design Challenges: 2008 11th IEEE International Symposium on Object and Component-Oriented Real-Time Distributed Computing (ISORC). 11th IEEE International Symposium on Object/Component/Service-Oriented Real-Time Distributed Computing (ISORC '08), 05.05.2008 - 07.05.2008, Orlando, FL, IEEE, 2008, S. 363–369
- [Mai98] MAIER, M. W.: Architecting principles for systems-of-systems. Systems Engineering, (1)4, 1998, S. 267–284
- [OL18] OLIVEIRA, M. I. S.; LÓSCIO, B. F.: What is a data ecosystem?: Proceedings of the 19th Annual International Conference on Digital Government Research: Governance in the Data Age. New York, NY, USA, ACM, New York, NY, USA, 2018
- [ÖO10] ÖSTERLE, H.; OTTO, B.: Consortium Research. Business & Information Systems Engineering, (2)5, 2010, S. 283–293
- [PM18] PAN, J.; MCELHANNON, J.: Future Edge Cloud and Edge Computing for Internet of Things Applications. IEEE Internet of Things Journal, (5)1, 2018, S. 439–449
- [VDI2206] Entwicklungsmethodik für mechatronische Systeme, 2004

2 Produktplanung auf Basis von Betriebsdaten

Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler

Im Rahmen des vorliegenden Buchs wird ein Instrumentarium für die Produktplanung auf Basis von Betriebsdaten vorgestellt. Hierfür ist zunächst eine Einführung in den theoretischen Hintergrund erforderlich. Gegenstand von Abschnitt 2.1 ist deshalb zunächst die Schaffung eines einheitlichen Verständnisses der grundlegenden Konzepte der Betriebsdaten-gestützten Produktplanung. Anschließend wird in Abschnitt 2.2 die Grundidee der Betriebsdaten-gestützten Produktplanung anhand der zugrundeliegenden Grundprinzipien erläutert und diese in ein Ablaufkonzept überführt. Das Kapitel schließt mit der Beleuchtung der Chancen und Herausforderungen der Betriebsdaten-gestützten Produktplanung in Abschnitt 2.3.

2.1 Grundlegende Konzepte

In den Abschnitten 2.1.1 bis 2.1.3 werden die grundlegenden Konzepte für eine Produktplanung auf Basis von Betriebsdaten vorgestellt, um ein einheitliches Verständnis der in der einschlägigen Literatur z. T. kontrovers diskutierten Begrifflichkeiten zu schaffen.

2.1.1 Strategische Produktplanung

Innerhalb des Referenzmodells der strategischen Planung und integrativen Entwicklung von Marktleistungen nach GAUSEMEIER ET AL. stellt die strategische Produktplanung den ersten Zyklus dar (vgl. Kapitel 1). Die Hauptaufgaben in der strategischen Produktplanung sind die Potentialfindung, Produktfindung und Geschäftsplanung (s. Bild 2-1). Diese charakterisieren das Vorgehen vom Finden der Erfolgspotentiale der Zukunft bis zum Erfolg versprechenden Entwicklungsauftrag. Ziel der **Potentialfindung** ist die Identifizierung der genannten Erfolgspotentiale sowie die Ermittlung entsprechender Handlungsoptionen. Innerhalb der sich anschließenden **Produktfindung** werden Produkt- und Dienstleistungsideen zum Ausschöpfen der Erfolg versprechenden Potentiale gesucht und ausgewählt. In der **Geschäftsplanung** wird zunächst eine Geschäftsstrategie erstellt. Darüber hinaus konkretisiert ein Geschäftsmodell das Nutzenversprechen. Auf Grundlage der Geschäftsstrategie sowie dem Geschäftsmodell erfolgt die Erarbeitung der Produktstrategie. Diese enthält Aussagen zur Gestaltung des Produktprogramms, zur wirtschaftlichen Bewältigung der vom Markt geforderten Variantenvielfalt, zu eingesetzten Technologien, zur Programmpflege über den Produktlebenszyklus etc. Die Produktstrategie mündet in einem Geschäftsplan, der den Nachweis erbringt, dass mit dem entwickelten Ansatz ein attraktiver Return on Investment zu erzielen ist [GDE+19], [GP14]. Zusammengefasst geben die Ergebnisse der strategischen Produktplanung den Unternehmen vor, wie die Produkte auszugestalten sind [UE16]. Dadurch entscheiden die in dieser Phase verorteten Aktivitäten über den Erfolg eines neuen Produktes [Coo19].

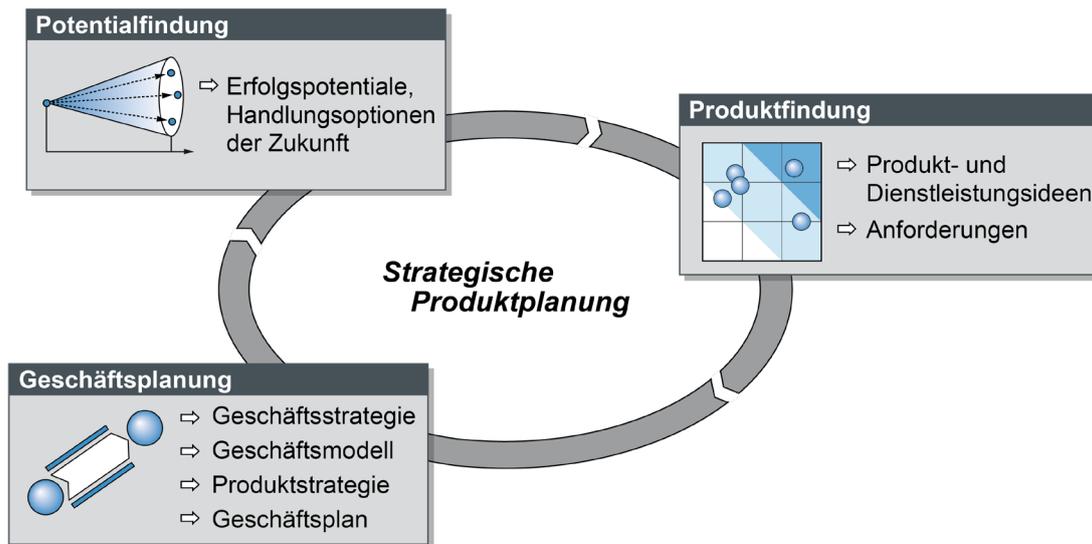


Bild 2-1: Zyklus der strategischen Produktplanung nach GAUSEMEIER ET AL. [GDE+19], [GP14]

Neben ihrem Einfluss auf den Produkterfolg hat die strategische Produktplanung auch einen erheblichen Einfluss auf die anderen Phasen des Produktlebenszyklus. Die Produktplanung weist zwar von allen Phasen die größte Gestaltungsfreiheit auf, gleichzeitig treten dort jedoch die größten Unsicherheiten auf. In der Produktplanung selbst fallen im Verhältnis zur Produktentwicklung kaum Kosten an. Allerdings werden die Kosten für die weiteren Phasen des Produktlebenszyklus maßgeblich bestimmt, da die in dieser Phase getroffenen Entscheidungen z. B. Auswirkungen auf die im Produkt einzusetzenden Technologien haben. In den folgenden Phasen nehmen die Kosten für Änderungen am Produkt stetig zu [HV04], [MS14]. Um die Erforderlichkeit von Produktänderungen zu minimieren, ist kundenseitig ein stetiger Input erforderlich. Durch eine kontinuierliche Integration des Kunden bereits in der Produktplanung kann sichergestellt werden, dass die Produkte den Kunden einen optimalen Mehrwert liefern [CL04]. Für die Integration des Kunden und Verringerung der Unsicherheiten in der Produktplanung werden Kundenbefragungen und Fokusgruppen-Interviews, Befragungen von Vertrieb und Service, die Analyse von Vertriebs- und Serviceberichten, Kreativitätsworkshops sowie Ideenwettbewerbe und Vorschlagslisten für Mitarbeiter und Kunden angewendet [Coo88]. Darüber hinaus können Marktstudien, Technologiestudien sowie Maßnahmen zur internen und externen Ideenfindung durchgeführt werden [Eve10].

Der Markt sowie die Kundenerwartungen und -bedürfnisse unterliegen in der Realität jedoch einer hohen Dynamik. Durch das Fünf-Kräfte-Modell nach PORTER wird beschrieben, dass der Wettbewerb in einer Branche durch fünf Kräfte geführt wird: Bedrohung durch neue Marktteilnehmer, Verhandlungsmacht der Zulieferer, Verhandlungsmacht der Abnehmer, Einfluss alternativer Produkte und Konkurrenzdruck unter den etablierten Wettbewerbern innerhalb der Branche [Por79]. Die jeweiligen Kräfte verursachen starke Wechselwirkungen untereinander, wodurch die Variation einer Kraft zu einer Variation aller Kräfte führt [Gru06]. Demnach befinden sich Märkte in einer steten Dynamik und

entwickeln sich kontinuierlich weiter. Dasselbe gilt für Kundenerwartungen und -bedürfnisse. Anhand des KANO-Modells werden Produktattribute in die Klassen Begeisterungsattribute, Leistungsattribute und Schwellenattribute klassifiziert [KST+84]. Die jeweiligen Attribute besitzen einen unterschiedlichen Einfluss auf die Kundenzufriedenheit. Hinzu kommt, dass die Zuordnung eines Attributs lediglich eine Momentaufnahme ist und sich mit der Zeit verändert [KST+84]. Für die Erzeugung einer langfristigen Kundenzufriedenheit müssen Produkte stetig mit neuen Attributen mit einem hohen Einfluss auf die Kundenzufriedenheit versehen und dadurch verbessert werden.

Anhand des Fünf-Kräfte-Modells und des KANO-Modells wird deutlich, dass Unternehmen hinsichtlich der Produktentwicklung nicht stagnieren dürfen. Erfolg versprechend ist nur eine stetige Verbesserung bestehender Produkte oder die Einführung gänzlich neuer Produkte. Die umfassende Überarbeitung eines bestehenden Produkts wird als neue Produktgeneration bezeichnet [GDE+19]. Die Planung neuer Produktgenerationen von im Feld befindlichen Produkten können als Teilaspekte der strategischen Produktplanung betrachtet werden. Die Entwicklung einer neuen Produktgeneration basiert in der Regel auf einem Referenzprodukt und dessen grundsätzlicher Struktur. Dabei können sowohl vorherige Produktgenerationen als auch Wettbewerbsprodukte als Referenzprodukte dienen [ABW15]. Eine neue Produktgeneration zeichnet sich insgesamt durch die selektive Übernahme bekannter Technologien bzw. durch die Erweiterung mit Neuen aus [TB18]. Das Ziel einer neuen Produktgeneration ist es, zukünftige bzw. aktuell ungelöste Kundenbedürfnisse zu erfüllen [HV07]. Ein weiterer strategischer Ansatz für produktverbessernde Maßnahmen ist nicht der Ersatz alter Systeme, sondern die Nachrüstung dieser, sodass sich die Nutzungsphase des Produktes verlängert. Insbesondere kleine, mittelständische Unternehmen (KMU) setzen im Kontext von Maschinen mit langen Lebenszyklen auf den Retrofit der sich im Feld befindlichen Produkte [KM15]. Hierdurch senkt sich das Risiko einer unzureichenden Produktkonzeption und steigert die Chancen auf einen nachhaltigen Produkterfolg [Coo19], [HLA12]. Im Zuge der Generationenplanung ist daher zu prüfen, welche Features nachgerüstet und welche in der neuen Produktgeneration implementiert werden sollen.

2.1.2 Betriebsdaten

Jedes Produkt durchläuft einen Lebenszyklus. Im Produktlebenszyklus-Management werden die folgenden drei Hauptphasen unterschieden: Anfang des Lebens (Beginning of Life, BOL), Mitte des Lebens (MOL) und Ende des Lebens (EOL). Die MOL umfasst die Nebenphasen Nutzung, Service sowie Wartung [Kir11], [TBD+10] und wird im Rahmen des vorliegenden Projekts fokussiert.

Für die in der Mitte des Lebens anfallenden und gesammelten Daten (hier: allgemein als Betriebsdaten bezeichnet) gibt es in der Literatur unterschiedliche Klassifizierungen und Bezeichnungen. BEVERUNGEN ET AL. unterteilen diese Daten in Nutzungsdaten, Kontext-

daten und Statusdaten [BMM+17]. KREUTZER bezeichnet die in der Nutzungsphase anfallenden Daten als Felddaten und unterteilt sie in drei Klassen: Technische Messungen, Nutzerdaten und Systemdaten [Kre19]. BALASUBRAMANIAN ET AL. unterteilen die Nutzungsphasendaten von Fahrzeugen in fünf Typen: Äußere Bedingungen, technischer Zustand der Ausrüstung, Produktnutzung, persönliche Daten und Präferenzen sowie direkte Kommunikation [BBC+16]. HOU und JIAO unterscheiden zwischen nutzergenerierten Daten, Produktbetriebsdaten und Umweltdaten [HJ20]. Ein Vergleich der Klassifizierungen zeigt, dass es Überschneidungen und Ähnlichkeiten der Klassen gibt, z. B. die Einteilung in nutzerorientierte, produktorientierte und kontextorientierte Daten. Für ein einheitliches Verständnis des Betriebsdaten-Begriffs wurde eine Taxonomie zur Klassifizierung der identifizierten Datenarten erarbeitet. Diese klassifiziert verschiedene Daten anhand von sieben Kriterien mit verschiedenen Ausprägungen (s. Tabelle 2-1).

Tabelle 2-1: Taxonomie zur Klassifizierung von Betriebsdatenarten

Kriterium	Ausprägungen			
Erzeuger	Mensch	Produkt		Umfeld
Struktur	Strukturiert		Semistrukturiert	
Entstehung	Kontinuierlich		Event-getriggert	
Beschreibungsfokus	Produkt	Umfeld	Nutzer	Kunde
Zweck	Erfassen		Veranlassen	
Erzeugungsfrequenz	Hoch	Mittel	Niedrig	
Informationsdichte	Hoch	Mittel	Niedrig	

Aufbauend auf der erarbeiteten Taxonomie konnten mit Hilfe einer hierarchischer Clusteranalyse (unter Anwendung der KNIME Analytics Plattform) fünf Cluster innerhalb der Datenarten identifiziert werden. Bild 2-2 zeigt das dazugehörige Dendrogramm sowie die zugrunde liegenden Datenarten. Im Folgenden wird jedes Cluster kurz charakterisiert [MPK+22]:

Nutzungsdaten beschreiben, wie ein Produkt von seinen Kunden und Nutzern verwendet wird. Diese Daten beziehen sich auf den Einsatz und die Anwendung des Produkts, nicht auf die Interaktion des Nutzers mit dem Produkt. Ein Beispiel für Nutzungsdaten sind Daten über die Nutzung von Funktionen und Merkmale eines Produkts.

Nutzerverhaltensdaten fassen zusammen, wie sich die Nutzer bei der Verwendung des Produkts verhalten. Im Gegensatz zu den Nutzungsdaten konzentrieren sich Nutzerverhaltensdaten auf die Interaktion des Nutzers mit dem Produkt. Benutzereinstellungsdaten sind ein Beispiel für Nutzerverhaltensdaten.

Servicedaten sind semistrukturierte Daten, die sich mit Problemen und der Qualität der Produkte befassen. Beispiele für diese Daten sind Serviceberichte und Informationen über Kundenreklamationen.

Produktverhaltensdaten zeigen die erbrachte Leistung eines Produktes im Betrieb. Sie zeichnen sich durch ihr großes Volumen und ihre kontinuierliche Erzeugung aus. Aktordaten sind ein Beispiel für diese Datenklasse.

Statusdaten beschreiben den Zustand des betrachteten Produkts. Diese Daten liefern den Kontext zu bestimmten Betriebssituationen. Beispiele für diese Daten sind Konfigurationsdaten und Logdateien.

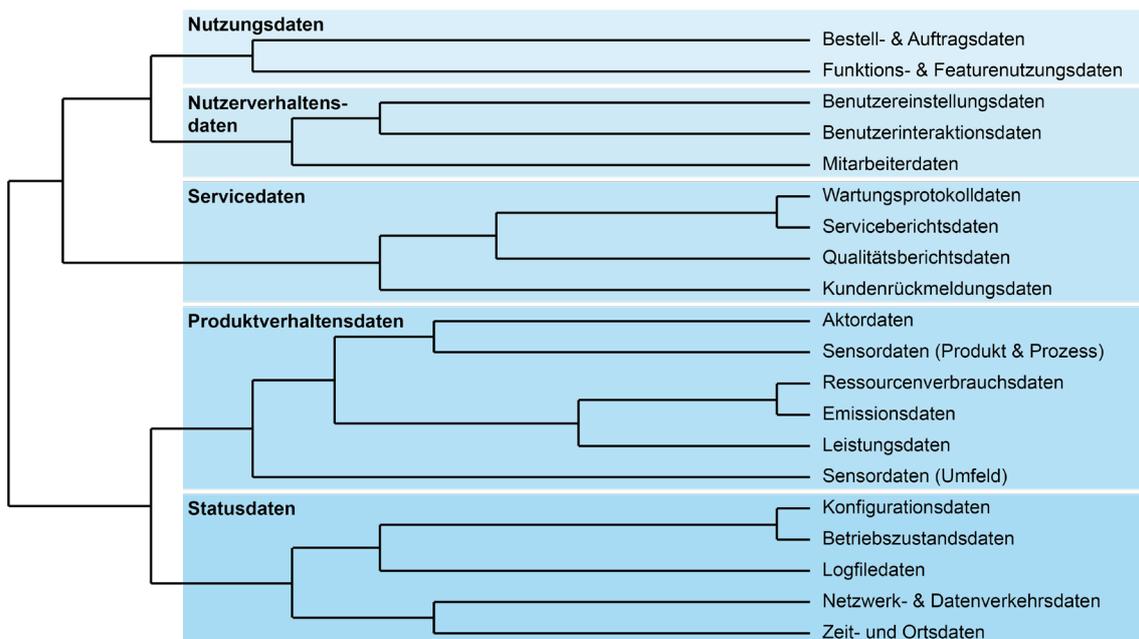


Bild 2-2: Dendrogramm zur Darstellung der fünf identifizierten Nutzungsphasen-Datencluster in Anlehnung an MEYER ET AL. [MPK+22]

Zusammenfassend ist festzuhalten, dass Betriebsdaten in der Betriebsphase des betrachteten Produkts entstehen. Zusätzlich muss die Datenentstehung mit dem Betrieb bzw. der Nutzung des Produkts zusammenhängen. Durch diese Einschränkung wird sichergestellt, dass nicht alle in der Betriebsphase anfallenden Daten zu Betriebsdaten des betrachteten Produkts erklärt werden.

2.1.3 Data Analytics

Technologische Fortschritte bei Big-Data-Architekturen sowie künstliche Intelligenz und maschinelles Lernen ermöglichen die effiziente Analyse von Big Data [LPW+16]. Der Prozess des Zugriffs, der Aggregation und der Analyse großer Datenmengen aus verschiedenen Quellen wird als Data Analytics bezeichnet. Data Analytics ermöglicht es Unternehmen, Wissen aus Daten zu extrahieren, um historische Ereignisse zu verstehen und zukünftige Ereignisse vorherzusagen [Tya03]. Das Wissen kann nicht nur über die Verarbeitung einzelner Messwerte generiert werden, sondern auch über die Ermittlung

von Mustern in einer Vielzahl von Werten. Anhand dieser Datenmuster besteht die Möglichkeit Ursachen von Problemen zu klären und richtig zu handeln. Die Generierung dieser Erkenntnisse ist die zentrale Aufgabe von Data Analytics [PH15].

Data Analytics bildet die Schnittmenge (s. Bild 2-3, links) zwischen den Disziplinen Mathematik & Statistik, Informatik & Informationstechnik sowie dem spezifischen Fachwissen aus den Anwendungsbereichen [LL20-ol]. Die analytischen Fähigkeiten aus dem Bereich der Mathematik und Statistik bilden die Grundlage zur Extraktion von Wissen aus Daten. Diese findet bspw. durch die Auswertung und Interpretation von (Vorhersage-) Modellen statt [SS14], [LL20-ol]. Ein weiterer Bestandteil ist die Informatik und Informationstechnik. In diesem Gebiet werden die Verfahren und technischen Systeme für die Sammlung, Aggregation, Speicherung und Analyse der Daten zur Verfügung gestellt [LL20-ol]. Ergänzt werden die wissenschaftlichen Disziplinen durch spezifisches Fachwissen aus dem jeweiligen Anwendungsbereich, bspw. der Fertigung [Rei16]. Dieses ist für ein Verständnis der Abläufe in einem Unternehmen essentiell und befähigt die Anwender zum Stellen der richtigen Fragen, um ein auftretendes Problem zu lösen. Darauf aufbauend werden die analytischen Fragestellungen aufgestellt [SS14].

Zur Strukturierung und Beschreibung von Aspekten eines Data-Analytics-Projekts sowie deren Zusammenhängen, kann das Industrial-Data-Analytics-Layer-Modell herangezogen werden (s. Bild 2-3, rechts).

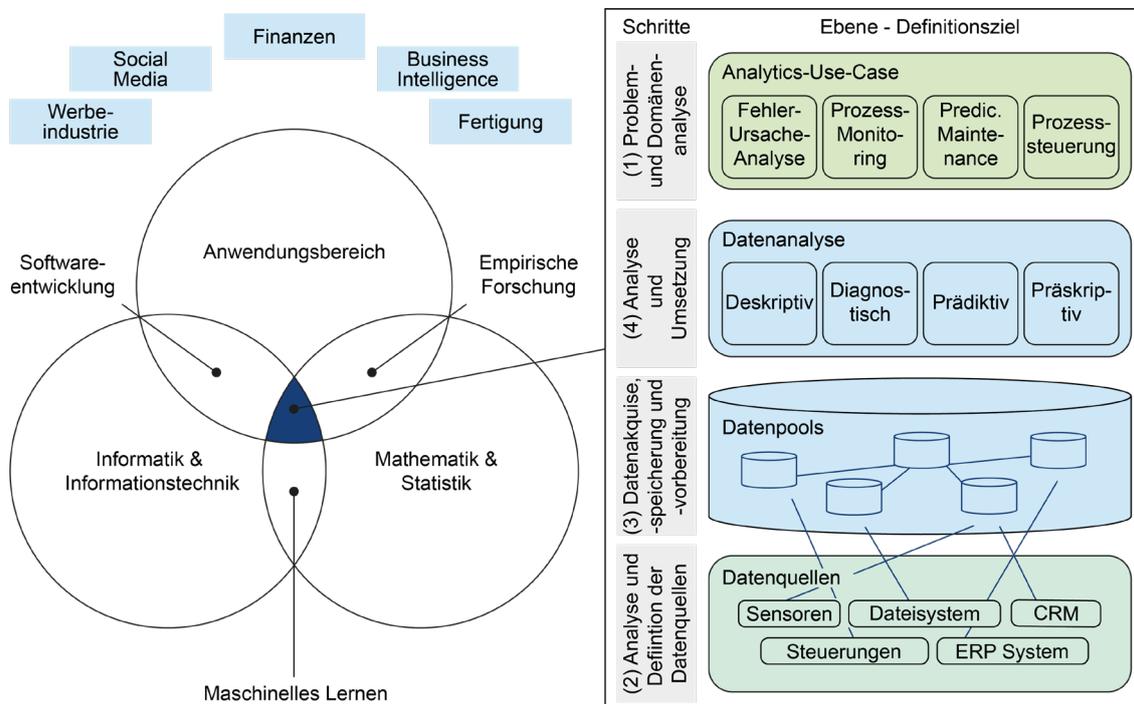


Bild 2-3: Charakterisierung und Ablauf von Data Analytics in Anlehnung an [Rei16], [KJR+18]

Das Modell unterscheidet zwischen den Ebenen „Analytics-Use-Case“, „Datenanalyse“, „Daten-Infrastruktur“ und „Datenquellen“ [KJR+18]. Der erste Schritt im Rahmen von

Data Analytics besteht darin das Problem zu verstehen und die Domäne zu analysieren. Das Ziel und das Ergebnis dieser Problemanalyse sind die Analytics-Use-Cases, wie bspw. die Durchführung eines Prozess-Monitorings [KJR+18]. Der zweite Schritt besteht in der Analyse und Definition der Datenquellen. Das heißt, es wird definiert, welche Sensoren oder Dateisysteme die Daten in welcher Form liefern. Hier müssen Experten aus den jeweiligen Bereichen einbezogen werden [KJR+18]. Im Anschluss werden die Daten erhoben, in Datenpools gespeichert und vorverarbeitet. Der letzte Schritt besteht in der Analyse der Daten [KJR+18]. Die Art der Analyse der Daten kann in vier Kategorien mit zunehmendem Wert und zunehmender Komplexität unterteilt werden: **deskriptiv** (Was ist passiert?), **diagnostisch** (Warum ist etwas passiert?), **prädiktiv** (Was wird passieren?) und **präskriptiv** (Wie soll ich mich verhalten?) [SSE+14].

LAVALLE ET AL. befragten mehr als 3000 Führungskräfte, Manager und Analysten zu den Herausforderungen und Chancen von Data Analytics [LLS+11]. Sie fanden unter anderem heraus, dass leistungsstarke Unternehmen Data Analytics fünfmal häufiger nutzen als weniger leistungsstarke Unternehmen. Der Einsatz von Data Analytics reicht von Managementaufgaben bis hin zum Tagesgeschäft [LLS+11].

2.2 Grundidee der Betriebsdaten-gestützten Produktplanung

Den heutigen Unternehmen stehen durch den zunehmenden Digitalisierungsgrad der Maschinen sowie der gesamten Wertschöpfungskette immer größer werdende Mengen an Daten zur Verfügung (vgl. Kapitel 1). Insbesondere durch die Entwicklungen im Zuge von Industrie 4.0 rücken Daten immer weiter in den Fokus. Betriebsdaten bieten den Unternehmen die Möglichkeit, Erkenntnisse über das Verhalten sowie die Nutzung ihrer Produkte zu gewinnen und diese zurück in die Planung fließen zu lassen [HSW+18]. Laut LUETH ET AL. und dem Research Report des HARVARD BUSINESS REVIEW ANALYTIC SERVICES haben viele Unternehmen diese Vorteile bereits erkannt. Dies äußert sich in den Wünschen nach mehr datengestützter Entscheidungsfindung und einer umfangreicheren Analyse der Produktnutzung in der Praxis [LPW+16], [Har18]. Die Analyse der Betriebsdaten (Data Analytics) sollte dabei zum frühestmöglichen Zeitpunkt im Entwicklungs- und Planungsprozess stattfinden [HHW+17]. Im Referenzmodell der strategischen Planung und integrativen Entwicklung von Marktleistungen nach GAUSEMEIER ist die erste Phase die strategische Produktplanung (vgl. Abschnitt 2.1.1).

Die Grundidee der Betriebsdaten-gestützten Produktplanung setzt sich somit aus den drei Forschungsfeldern Strategische Produktplanung, Digitalisierung von Produkten sowie Data Analytics zusammen. Die jeweiligen Schnittmengen der Forschungsfelder repräsentieren die drei Grundprinzipien der Betriebsdaten-gestützten Produktplanung (s. Bild 2-4), welche im Folgenden charakterisiert werden:

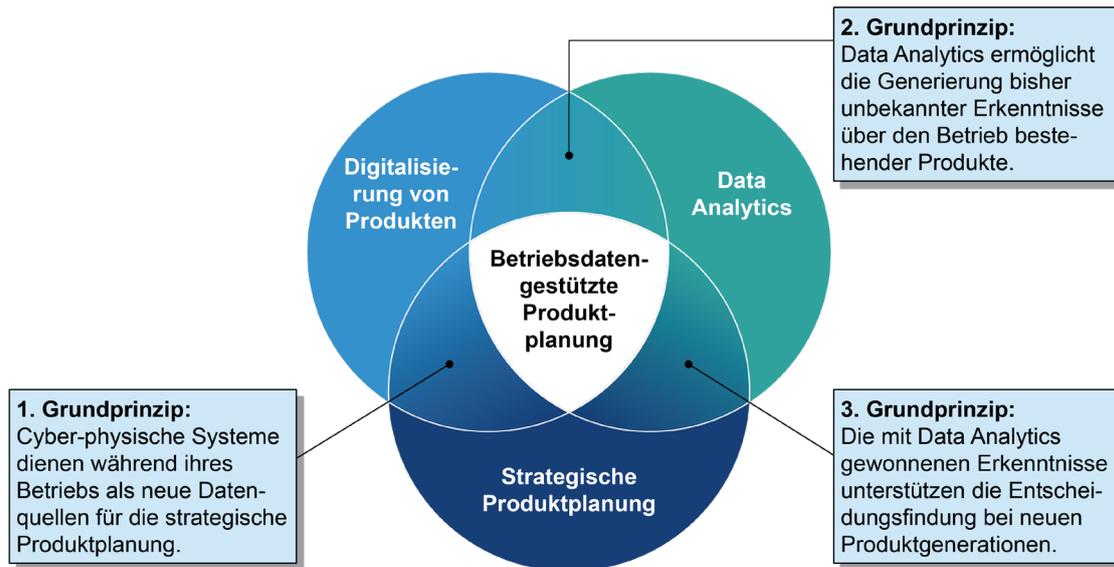


Bild 2-4: Grundprinzipien der Betriebsdaten-gestützten Produktplanung

1. Grundprinzip: *Cyber-physische Systeme dienen während ihres Betriebs als neue Datenquellen für die strategische Produktplanung.*

Auftragsentwicklungen, Kundendienstbesuche, Umfragen und Marktforschungen sind Beispiele für traditionelle Informationsquellen, die in der strategischen Produktplanung genutzt werden, um Verbesserungspotentiale für bestehende Produkte zu identifizieren (vgl. Abschnitt 2.1.1). Durch den Wandel der Maschinen- und Anlagen von mechatronischen zu cyber-physischen Systemen sowie Fortschritten bei der digitalen Infrastruktur werden die traditionellen Datenquellen um eine neue Ressource ergänzt – die Betriebsdaten der Produkte. Die Betriebsdaten können den Herstellern über ein Netzwerk bereitgestellt werden und liefern weitreichende Informationen über die Produkte, Prozesse, Kunden und Nutzer. In diesem Umfang und dieser Transparenz stand eine solche Informationsbasis bisher nicht zur Verfügung (vgl. Abschnitt 2.1.2).

2. Grundprinzip: *Data Analytics ermöglicht die Generierung bisher unbekannter Erkenntnisse über den Betrieb bestehender Produkte.*

Die in großen Mengen zur Verfügung stehenden Betriebsdaten ermöglichen wertvolle Einblicke in die Betriebsphase der Produkte und weisen daher ein hohes Nutzenpotential für die Hersteller auf (vgl. Abschnitt 2.1.2). Aufgrund des Umfangs der anfallenden Datenmengen, ist eine manuelle Analyse jedoch nicht mehr möglich. Mit Hilfe von Data-Analytics-Verfahren können jedoch auch große Mengen heterogener Daten analysiert werden und tiefgreifende Erkenntnisse über die Produkte, Prozesse, Kunden und Nutzer liefern. Auf dieser Grundlage können Innovationspotentiale identifiziert und Wettbewerbsvorteile erzielt werden (vgl. Abschnitt 2.1.3).

3. Grundprinzip: *Die mit Data Analytics gewonnenen Erkenntnisse unterstützen die Entscheidungsfindung bei neuen Produktgenerationen.*

Die mit Hilfe von Data Analytics gewonnenen Erkenntnisse bieten den Unternehmen objektive und zuverlässige Informationen für die Entscheidungsfindung. Aufgrund der verschiedenen Arten der Analyse kann die Hilfestellung verschiedene Formen annehmen – von der Schaffung einer verbesserten Entscheidungsgrundlage bis hin zur Vorgabe konkreter Maßnahmen (vgl. Abschnitt 2.1.3). Die Erkenntnisse der Datenanalysen können in der strategischen Produktplanung dazu genutzt werden Unsicherheiten in Bezug auf sinnvolle Verbesserungen der Produkte zu reduzieren und mit hohen Kosten verbundene Fehlentscheidungen zu vermeiden (vgl. Abschnitt 2.1.1).

Ablaufkonzept der Betriebsdaten-gestützten Produktplanung

Im Zusammenspiel stellen die drei Grundprinzipien den Ausgangspunkt für das Ablaufkonzept der Betriebsdaten-gestützten Produktplanung dar. Dieses setzt bei der Planung neuer Produktgenerationen an, welche auf eine präzise Definition der zu entwickelnden Produkte abzielt [Coo19]. Allerdings stehen die Unternehmen vor der Herausforderung, dass belastbare Kenntnisse darüber fehlen, wie Kunden die Produkte nutzen bzw. einsetzen. Dadurch herrscht Unklarheit über die spezifischen, marktseitigen Anforderungen an das Produkt. Dies hat zur Folge, dass die Produktplanung und die zu treffenden Entscheidungen durch große Unsicherheiten gekennzeichnet sind.

Ergebnis dieses Informationsdefizites ist eine Ausgestaltung des Produkts, die auf Annahmen statt auf Fakten beruht. Hierbei besteht das Risiko, dass die gewählten Produktattribute nicht den spezifischen Anforderungen entsprechen und eine mangelnde Kundenorientierung aufweisen [HV04]. Diese Unsicherheiten treten nicht bei jedem geplanten Produkt neu auf. Vielmehr kumulieren sie sich über die aufeinanderfolgenden Produktgenerationen hinweg (vgl. Abschnitt 2.1.1). In einer Studie mit 247 Ingenieuren fanden ALBERS ET AL. heraus, dass nur 7 % der Entwicklungen völlig neue Produkte betreffen. Dagegen betreffen 93 % der Produktentwicklungsprojekte die evolutionäre Weiterentwicklung bestehender Produkte [ABU+14]. Eine direkte Folge daraus ist, dass Produkte sowohl hinsichtlich alter (weil z. B. Anforderungen von einer Produktgeneration zur nächsten übernommen werden) als auch gänzlich neuer (z. B. in Folge einer veränderten Wettbewerbssituation) Unsicherheiten und Annahmen überprüft werden müssen [FAH+11].

Um eine präzise Produktdefinition zu ermöglichen und kostspielige Änderungen in späteren Lebenszyklusphasen zu vermeiden (vgl. Abschnitt 2.1.1), ist es notwendig, dass innerhalb der Produktplanung so viele Unsicherheiten wie möglich aufgelöst und Annahmen überprüft werden. Traditionell war die Beschaffung von qualitativ hochwertigen Informationen aus der Nutzungsphase jedoch schwierig [DWH+21]. Durch das Aufkommen von cyber-physischen Systemen können jedoch Betriebsdaten für die Überprüfung der Unsicherheiten und Annahmen herangezogen werden.

Die sich im Feld befindlichen Produktgenerationen generieren und sammeln während des Betriebs kontinuierlich Daten über sich selbst, ihre Nutzer sowie ihre Umwelt (vgl. Abschnitt 2.1.2). Durch die Vernetzung der Produkte werden die Betriebsdaten der unterschiedlichen Instanzen über die digitale Netzinfrastruktur an einem zentralen Ort gespeichert (z. B. in der Cloud) und stehen den Unternehmen zur Verfügung [ALW+11], [vOL12]. Im Rahmen der Data-Analytics-Prozesse werden die strukturiert oder unstrukturiert vorliegenden Rohdaten transformiert, sodass sie für eine anschließende Datenpflege, -speicherung und -nutzung bereitstehen [DLF+16]. Die Datensätze werden anschließend mit statistischen Analysen, Data Mining und maschinellen Lernmethoden untersucht, um Zusammenhänge und Muster in den Daten zu identifizieren [HJ20], [IAG+15], [Run20]. Die Ergebnisse der Datenanalyse bilden die Grundlage für die Entstehung neuen Wissens (z. B. über die Nutzung des Produkts durch die Kunden) und dadurch die Eliminierung der Unsicherheiten sowie Verminderung von Risiken [JSK+07], [vOL12, S. 870]. Die gewonnenen Erkenntnisse werden genutzt, um Verbesserungspotentiale datengestützt abzuleiten und diese in die Planung zukünftiger, verbesserter Produktgenerationen einfließen zu lassen. Dadurch werden Entscheidungen ermöglicht, die auf Fakten statt auf Annahmen basieren [HNU+17], [WHT14], [XFR16].

Bild 2-5 zeigt das Ablaufkonzept der Betriebsdaten-gestützten Produktplanung.

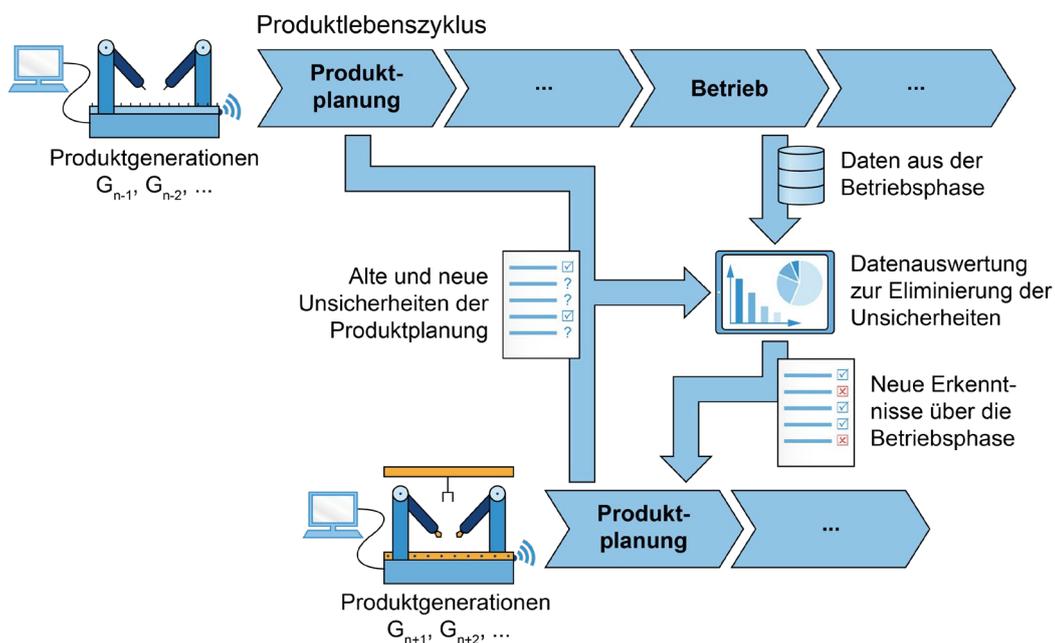


Bild 2-5: Ablaufkonzept der Betriebsdaten-gestützten Produktplanung

Hervorzuheben ist an dieser Stelle, dass das beschriebene Konzept kein Ersatz für die etablierten Produktplanungsaktivitäten und -methoden sowie die Erfahrungen von Produktexperten darstellt. Es handelt sich vielmehr um eine Ergänzung der etablierten Produktplanung sowie ihrer traditionellen Daten- und Informationsquellen [WTH+17]. Durch das regelmäßige Zurückspielen von Informationen und Wissen über den Betrieb der Produkte wird ein verbessertes und wissensbasiertes Vorgehen ermöglicht [HJ20].

2.3 Chancen und Herausforderungen der Betriebsdaten-gestützten Produktplanung

Die Grundidee der Betriebsdaten-gestützten Produktplanung (vgl. Abschnitt 2.2) zeigt auf, welches Potential das Zusammenspiel der drei Forschungsfelder Strategische Produktplanung, Digitalisierung von Produkten und Data Analytics birgt. Folglich gilt es die Betriebsdaten-gestützte Produktplanung zukünftig als eine Kernfähigkeit in den Unternehmen zu etablieren. Damit gehen für die Unternehmen vielfältige Chancen und Herausforderungen einher. Diese werden folgend kurz vorgestellt.

Chancen der Betriebsdaten-gestützten Produktplanung

Die Literatur führt zahlreiche positive Aspekte der Betriebsdaten-gestützten Produktplanung auf. Sie lassen sich zu vier grundlegenden Vorteilen zusammenfassen, die die Analyse von Betriebsdaten gegenüber den traditionellen Methoden zur Identifizierung von Verbesserungspotentialen (vgl. Abschnitt 2.1.1) bietet:

- (1) **Umfassende Datenbasis:** Cyber-physische Systeme generieren und sammeln während des Betriebs kontinuierlich Daten über die Produkte, Kunden und Prozesse. Aufgrund der Tatsache, dass die Daten über ein breites Spektrum an Kunden und Produktinstanzen und in einer großen Menge erhoben werden, bieten sie tiefere Einblicke in die Produkte als etablierte Methoden der Informationserhebung (Interviews, Umfragen etc.) [PH15]. Darüber hinaus erfordern sie einen geringeren Ressourceneinsatz. Zusätzlich werden durch eine Datenerhebung über alle Produktinstanzen hinweg verschiedene Fokussierungen im Rahmen der Analyse ermöglicht. Bspw. können Analysen über alle Instanzen im Feld durchgeführt werden. Darüber hinaus besteht die Möglichkeit, dass lediglich eine beliebige Teilmenge (z. B. differenziert nach Produktvarianten oder Ländern) analysiert wird [HUB16], [HJ20].
- (2) **Besseres Kundenverständnis:** Anhand der Daten lassen sich die Betriebs- und Nutzungsprofile der betrachteten Produkte quantifizieren. Das bedeutet das sowohl die Häufigkeit als auch die Art der Nutzung von Produkten sowie deren Features ausgewertet werden können, um das Kunden- und Nutzerverhalten besser nachzuvollziehen. Hierbei können sowohl Vorlieben als auch latente Bedürfnisse der Kunden und Nutzer identifiziert und die Produkte entsprechend darauf ausgerichtet werden [MFK+22], [HJ20]. Die gewonnenen Erkenntnisse können anschließend dazu genutzt werden, Kundensegmente besser voneinander abzugrenzen [LTC+15].
- (3) **Besseres Produktverständnis:** Mit Hilfe der Daten (insb. der Produktverhaltens- und Statusdaten, vgl. Abschnitt 2.1.2) können sowohl die Leistung als auch das Verhalten der Produkte im Betrieb nachvollzogen und eingeordnet werden [MPK+22]. Aufgrund der darüber hinaus enthaltenen Kontextinformationen (bspw. mit welchen Grundeinstellungen eine Maschine verwendet wird) helfen

sie dabei, auftretende Fehler besser zu verstehen und deren Ursachen zu identifizieren [WSK+17]. Außerdem können die Daten dazu verwendet werden Aussagen von Maschinenbedienern oder Servicereports sowohl zu quantifizieren als auch zu kontextualisieren und entsprechende Maßnahmen daraus abzuleiten [HUB16].

- (4) **Validere Entscheidungen:** Die Analyse von Betriebsdaten verringert die in der Produktplanung vorherrschenden Unsicherheiten (vgl. Abschnitt 2.1.1), indem sie Entscheidungen ermöglicht, welche sich am konkreten Betrieb und der Nutzung der Produkte orientiert [HNU+17]. Dadurch werden anfallende Entscheidungen nicht nur auf Grundlage von Erfahrungswerten getroffen, sondern beruhen auf Fakten aus dem laufenden Betrieb [WHT14], [HSU+16]. Anhand der gewonnenen Erkenntnisse über das Produkt sowie dessen Nutzung können bspw. Over-Engineering oder überflüssige Features identifiziert werden. Hieraus ergeben sich zugleich Erwartungen sowie Anforderungen an die neue Produktgeneration und schlussendlich eine validere Entscheidungsgrundlage in der Produktplanung [MFK+22].

Herausforderungen der Betriebsdaten-gestützten Produktplanung

Bei der Umsetzung einer Betriebsdaten-gestützten Produktplanung stehen die Unternehmen jedoch vor vielfältigen Herausforderungen. Im Rahmen einer Interviewstudie¹ wurden zentrale Herausforderungen der Betriebsdaten-gestützte Produktplanung herausgearbeitet [MFK+22]. Diese Herausforderungen gilt es im Rahmen der Einführung bzw. Umsetzung einer Betriebsdaten-gestützten Produktplanung zu adressieren. Sie werden im Folgenden kurz erläutert:

- (1) **Die Produkte sind zu komplex für einfache Datenanalysen und Schlussfolgerungen:** Die hohe Komplexität der Produkte führt dazu, dass eine nahezu unendlich hohe Zahl verschiedener Fehlermeldungen und unendlich viele Szenarien zur Entstehung der Fehlermeldungen möglich sind. Das Level der Komplexität bzw. die hohe Anzahl möglicher Fehlerszenarien erschwert einfache Datenanalysen (wie bspw. eine Korrelationsanalyse) und das Ableiten von Schlussfolgerungen. Das hat zur Folge, dass die Ursachenfindung sehr ressourcenaufwändig ist. Darüber hinaus erfordert eine erfolgreiche Ursache-Wirkungs-Analyse ein umfangreiches Wissen über das Produkt sowie entsprechende Kontextinformationen der Untersuchung. Die Unternehmen haben jedoch oft nur wenige Experten für eine solche Untersuchung zur Verfügung.
- (2) **Die Produkte liefern zu wenig Daten:** Trotz der voranschreitenden Entwicklung der Produkte hin zu cyber-physischen Systemen verfügen viele Produkte im Feld noch über wenige Sensoren, sodass die Datensammlung erschwert wird. Hinzu kommt die fehlende Netzanbindung der Produkte. Um die Verbindungsraten zu erhöhen, entwickeln die Unternehmen derzeit Lösungen wie IoT-Konnektoren

¹ Die Interviewstudie wurde mit Entscheidungsträgern von acht Maschinen- und Anlagenbauern durchgeführt. Zwei der Unternehmen stammten aus dem Konsortium.

oder spezifische Schnittstellen. Hinzu kommt, im B2B-Bereich (Business-to-Business) viel weniger Exemplare eines Produkts verkauft werden als im B2C-Bereich (Business-to-Consumer). Gerade im B2B-Bereich werden Produkte oft individuell für jeden Kunden gestaltet oder nach dem Kauf und der Inbetriebnahme durch den Kunden modifiziert. Daher wird erwartet, dass der Erhalt von Daten in ausreichender Menge auch in Zukunft ein Problem darstellen wird.

- (3) **Kunden wollen oder können die Daten der Nutzungsphase nicht teilen:** Häufig sehen Kunden keinen Nutzen darin die Daten den Herstellern zur Verfügung zu stellen. Sie fürchten den Abfluss von Know-how oder eine systematische Überwachung. Insbesondere große Unternehmen und Konzerne sind bei der gemeinsamen Nutzung von Daten sehr viel restriktiver als kleinere Unternehmen. Darüber hinaus herrscht prinzipiell Unklarheit bei der Frage, wem die Daten und vor allem das daraus gewonnene Wissen gehören. Selbst wenn die Kunden eine Rückmeldung der Daten nicht grundsätzlich ausschließen, gewähren sie in den meisten Fällen dennoch keinen dauerhaften Vollzugriff auf die Daten, sondern nur einen temporären Zugriff. Eine alleinige Bereitschaft der Kunden für den Datenaustausch reicht in vielen Fällen jedoch noch nicht aus. Selbst wenn diese prinzipiell besteht, ist der Aufbau einer entsprechenden Verbindung zum Kunden meist mit einem immensen Aufwand und hohen Kosten verbunden.
- (4) **Die Umsetzung erfordert neue Prozesse und Infrastrukturen:** Die Einführung einer Betriebsdaten-gestützten Produktplanung erfordert einen klar definierten Prozess sowie eine Methodik, die auf das Ziel fokussiert und nicht übersystematisiert ist. Insbesondere bei der Analyse der Daten und der Verwertung der Analyse-Ergebnisse sehen die Unternehmen spezifische Hindernisse. Dies bezieht sich insbesondere auf das Ziehen der richtigen Schlüsse aus den vorliegenden Daten. Bei der Interpretation ist Expertenwissen erforderlich, sodass Korrelation und Kausalität zwischen den Datensätzen richtig eingeordnet werden. Zusätzlich hemmt die digitale Inkonsistenz (Einsatz einer Vielzahl verschiedener Tools und Datenbanken) die Umsetzung. Diese Punkte erschweren die Zusammenführung und gemeinsame Auswertung verschiedener Daten immens.
- (5) **Unternehmen fehlt es an Datenkompetenz:** Aufgrund der eher traditionellen Ausrichtung der Maschinenbaubranche fehlt es den Beschäftigten häufig an der erforderlichen Datenkompetenz. Trotz der zunehmenden Bedeutung datengestützter Methoden, weisen viele Unternehmen bisher nur wenig Erfahrungen auf. Um dem entgegenzuwirken, greifen einige Unternehmen derzeit auf externe Datenexperten zurück oder planen neue Stellen für die Datenanalyse. Der Einsatz externer oder interner Datenexperten ist jedoch nicht ausreichend. Datenexperten fehlt das technische Gesamtverständnis, um die richtigen Rückschlüsse aus den Datenanalyse-Ergebnissen zu ziehen.

Handlungsbedarf für die Betriebsdaten-gestützten Produktplanung

Durch das Zusammenspiel der drei Grundprinzipien der Betriebsdaten-gestützten Produktplanung wird diese zu einer sozio-technischen Herausforderung. Produkte müssen über die digitale Infrastruktur angebunden werden (Technik), neue Prozesse müssen definiert werden (Organisation) und Mitarbeiter benötigen neue Kompetenzen (Mensch). Dies verdeutlicht, dass das Thema kein triviales ist. Gleichwohl gehen mit der Betriebsdaten-gestützten Produktplanung vielfältige Chancen einher. Die Unternehmen erhalten eine umfassende Datenbasis, können ein besseres Kunden- und Produktverständnis aufbauen und werden in die Lage versetzt, auf Fakten basierende Entscheidungen bei der Planung neuer Produktgenerationen zu treffen. Den Chancen stehen jedoch ebenso vielfältige Herausforderungen gegenüber, die es auf dem Weg zu einer Betriebsdaten-gestützten Produktplanung zu bewältigen gilt. Aus diesem Grund bedarf es eines Instrumentariums, welches die Unternehmen bei der Einführung einer Betriebsdaten-gestützten Produktplanung unterstützt und entsprechende Prozesse, Methoden und Werkzeuge zur Verfügung stellt.

Literatur zu Kapitel 2

- [ABU+14] ALBERS, A.; BURSAC, N.; URBANEC, J.; LÜDCKE, R.; RACHENKOVA, G.: Knowledge Management in Product Generation Development - an empirical study. Design for X – Beiträge zum 25. DfX-Symposium, TUHH Universitätsbibliothek, Hamburg, Germany, 2014, S. 13–24
- [ABW15] ALBERS, A.; BURSAC, N.; WINTERGERST, E.: Produktgenerationsentwicklung – Bedeutung und Herausforderungen aus einer entwicklungsmethodischen Perspektive. In: Binz, H.; Bertsche, B.; Bauer, W.; Roth, D. (Hrsg.): Stuttgarter Symposium für Produktentwicklung (SSP) 2015 –Entwicklung smarterer Produkte für die Zukunft. Stuttgarter Symposium für Produktentwicklung (SSP), 19. Juni 2015, Stuttgart, 2015
- [ALW+11] ABRAMOVICI, M.; LINDNER, A.; WALDE, F.; FATHI, M.; DIENST, S.: Decision support for improving the design of hydraulic systems by leading feedback into product development. In: ICED 2011 (Hrsg.): Proceedings of the 18th International Conference on Engineering Design (ICED 11), Impacting Society through Engineering Design, Vol. 1: Design Processes. 15.-19. August 2011, Lyngby/Copenhagen, Denmark, 2011
- [BBC+16] BALASUBRAMANIAN, J.; BEIKER, S.; CHAUHAN, S.; COLOMBO, T.; HANSSON, F.; INAMPUDI, S.; JAARMA, R.; KÄSSER, M.: Car data: paving the way to value-creating mobility: Perspectives on a new automotive business model. McKinsey&Company, 2016
- [BMM+19] BEVERUNGEN, D.; MÜLLER, O.; MATZNER, M.; MENDLING, J.; VOM BROCKE, J.: Conceptualizing smart service systems. Electronic Markets, (29)1, 2019, S. 7–18
- [Bue16] BUERKE, G.: Marktforschungsmethoden für Innovationen und Produktverbesserungen. Wirtschaftswissenschaftliche Schriften (Marktorientierte Unternehmensführung) Heft 2016/03, Ernst-Abbe-Hochschule Jena, Fachbereich Betriebswirtschaft, Jena, 2016
- [CL04] CALLAHAN, J.; LASRY, E.: The importance of customer input in the development of very new products. R&D Management, (34)2, 2004, S. 107–120
- [Coo19] COOPER, R. G.: The drivers of success in new-product development. Industrial Marketing Management, (76), 2019, S. 36–47
- [Coo88] COOPER, R. G.: Predevelopment activities determine new product success. Industrial Marketing Management, (17)3, 1988, S. 237–247

- [DLF+16] DOMINGUE, J.; LASIERRA, N.; FENSEL, A.; VAN KASTEREN, T.; STROHBACH, M.; THALHAMMER, A.: Big Data Analysis. In: Cavanillas, J. M.; Curry, E.; Wahlster, W. (Hrsg.): *New Horizons for a Data-Driven Economy*. Springer International Publishing, Cham, 2016, S. 63–86
- [DWH+21] DENG, Q.; WELLSANDT, S.; HRIBERNIK, K.; THOBEN, K.-D.: Understanding Users and Products in Product Development: The Application of Product Usage Information and its Challenges. In: ICED 2021 (Hrsg.): *Proceedings of the International Conference on Engineering Design (ICED21)*. 16.-20. August 2021, Gothenburg, Sweden, Cambridge University Press, 2021, S. 3299–3308
- [Eve10] EVELEENS, C.: *Innovation management; a literature review of innovation process models and their implications*. Nijmegen, NL, 2010
- [FAH+11] FATHI, M.; ABRAMOVICI, M.; HOLLAND, A.; LINDNER, A.; DIENST, S.: Nutzungs-Szenarien eines wissensbasierten Assistenzsystems zur Entscheidungsunterstützung in der Produktverbesserung. In: Maier, R. (Hrsg.): *Proceedings of the 6th Conference on Professional Knowledge Management – From Knowledge to Action*. 21.-23. February 2011, Innsbruck, Austria, Gesellschaft für Informatik e.V., 2011, S. 295–304
- [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
- [GP14] GAUSEMEIER, J.; PLASS, C.: *Zukunftsorientierte Unternehmensgestaltung – Strategien, Geschäftsprozesse und IT-Systeme für die Produktion von morgen*. 2. Auflage, Hanser, München, 2014
- [Gru06] GRUNDY, T.: Rethinking and reinventing Michael Porter’s five forces model. *Strategic Change*, (15)5, 2006, S. 213-229
- [GSK+14] GEISSBAUER, R.; SCHRAUF, S.; KOCH, V.; KUGE, S.: *Industrie 4.0 – Chancen und Herausforderungen der vierten industriellen Revolution*, 2014
- [Har18] HARVARD BUSINESS SCHOOL PUBLISHING (HRSG.): *Leading in a World of Continuous Change – A Roadmap for Rapid Technology Adoption*. Harvard Business Review Analytic Services, Research Report, 2018
- [HHW+17] HÖHN, M.; HOLLAUER, C.; WILBERG, J.; KAMMERL, D.; MÖRTL, M.; OMER, M.: Investigation usage data Support in development processes - a case study. In: ICED 2017 (Ed.): *Proceedings of the 21st International Conference on Engineering Design (ICED17)*, Vol. 7: Design Theory and Research Methodology. 21.-25. August 2017, Vancouver, Canada, DS, 87, 7, Curran Associates Inc, Red Hook, NY, 2017, pp. 91–100
- [HJ20] HOU, L.; JIAO, R. J.: Data-informed inverse design by product usage information: a review, framework and outlook. *Journal of Intelligent Manufacturing*, (31)3, 2020, S. 529–552
- [HLA12] HUSSAIN, R.; LOCKETT, H.; ANNAMALAI VASANTHA, G. V.: A framework to inform PSS Conceptual Design by using system-in-use data. *Computers in Industry*, (63)4, 2012, S. 319–327
- [HNU+17] HOLLER, M.; NEIDITSCH, G.; UEBERNICKEL, F.; BRENNER, W.: Digital product innovation in manufacturing industries towards a taxonomy for feedback-driven product development scenarios. In: HICSS 2017 (Ed.): *Proceedings of the 50th Hawaii International Conference on System Sciences (HICSS-50)*. 4.-7. January 2017, Waikoloa Village, Hawaii, AIS Electronic Library (AISeL), 2017
- [HSU+16] HOLLER, M.; STOECKLI, E.; UEBERNICKEL, F.; BRENNER, W.: Towards Understanding closed-loop PLM: The Role of Product Usage Data for Product Development enabled by intelligent Properties. In: BLED 2016 (Hrsg.): *BLED 2016 Proceedings. 29th Bled eConference Digital Economy*, 19.-22. June 2016, Bled, Slovenia, 2016, S. 479–491

- [HSW+18] HOLLAUER, C.; SHALUMOV, B.; WILBERG, J.; OMER, M.: Graph databases for exploiting use phase data in product-service-system development: a methodology to support implementation. In: Design 2018 (Hrsg.): Proceedings of the DESIGN 2018 15th International Design Conference. 15th International Design Conference, 21.-24. May 2018, Design Conference Proceedings, Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, Croatia, The Design Society, Glasgow, UK, 2018, S. 1571–1582
- [HUB16] HOLLER, M.; UEERNICKEL, F.; BRENNER, W.: Understanding the Business Value of Intelligent Products for Product Development in Manufacturing Industries. In: ICIME 2016 (Hrsg.): Proceedings of the 8th International Conference on Information Management and Engineering - ICIME 2016. Association for Computing Machinery (ACM), 02.- 05. November 2016, Istanbul, Turkey, ACM Press, New York, USA, 2016, S. 18–24
- [HV04] HERSTATT, C.; VERWORN, B.: The ‘Fuzzy Front End’ of Innovation. In: EITIM (Hrsg.): Bringing Technology and Innovation into the Boardroom. Palgrave Macmillan UK, London, 2004, S. 347–372
- [HV07] HERSTATT, C.; VERWORN, B. (Hrsg.): Management der frühen Innovationsphasen – Grundlagen - Methoden - Neue Ansätze. 2. Auflage, Gabler, Wiesbaden, 2007
- [IAG+15] IGBA, J.; ALEMZADEH, K.; GIBBONS, P. M.; HENNINGSEN, K.: A framework for optimising product performance through feedback and reuse of in-service experience. Robotics and Computer-Integrated Manufacturing, (36), 2015, S. 2–12
- [JSK+07] JUN, H.-B.; SHIN, J.-H.; KIRITSIS, D.; XIROUCHAKIS, P.: System architecture for closed-loop PLM. International Journal of Computer Integrated Manufacturing, (20)7, 2007, S. 684–698
- [Kir11] KIRITSIS, D.: Closed-loop PLM for intelligent products in the era of the Internet of things. Computer-Aided Design, (43)5, 2011, S. 479–501
- [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
- [Kre19] KREUTZER, R.: Methodik zur Bestimmung der Nutzenpotenziale von Felddaten cyberphysischer Systeme. Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen; Apprimus Verlag, 2019
- [KST+84] KANO, N.; SERAKU, N.; TAKAHASHI, F.; TSUJI, S.: Attractive Quality and Must-Be Quality. Journal of the Japanese Society for Quality Control, (14)2, 1984, S. 147–156
- [LL20-ol] LUBER, S.; LITZEL, N.: Definition – Was ist Data Science? BIGDATAINSIDER. Unter: <https://www.bigdata-insider.de/was-ist-data-science-a-979153/>, 23. Juni 2022
- [LLS+11] LAVALLE, S.; LESSER, E.; SHOCKLEY, R.; HOPKINS, M. S.; KRUSCHWITZ, N.: Big Data, Analytics and the Path from Insights to Value. MIT Sloan, Vol. 52, 2011
- [LPW+16] LUETH, K. L.; PATSIOURA, C.; WILLIAMS, Z. D.; KERMANI, Z. Z.: Industrial Analytics 2016/2017 – The current state of data analytics usage in industrial companies. IoT Analytics, Hamburg, 2016
- [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
- [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
- [MK15] MEIER ZU KÖCKER, G.; KÜNZEL, M.: Werkstattpapier Industrie 4.0 – die Rolle der Cluster-Initiativen im Wandel der Wertschöpfungsketten. Stuttgart, 2015
- [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

- [MPK+22] MEYER, M.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: 17 Use Cases for Analyzing Use Phase Data in Product Planning of Manufacturing Companies. *Procedia CIRP*, (107), 2022, S. 1053–1058
- [MS14] MACHAC, J.; STEINER, F.: Risk Management in Early Product Lifecycle Phases. *International Review of Management and Business Research*, (3)2, 2014, S. 1151–1162
- [PH15] PORTER, M. E.; HEPPELMANN, J. E.: How Smart, Connected Products Are Transforming Companies. *Harvard Business Review*, (93)10, 2015, S. 96–112
- [Por79] PORTER, M. E.: How Competitive Forces Shape Strategy. *Harvard Business Review*, (57), 1979, S. 137–145
- [Rei16] REINHART, F.: Industrial Data Science - Data Science in der industriellen Anwendung. *Industrie 4.0 Management*, (32), 2016, S. 27–30
- [Run20] RUNKLER, T. A.: Introduction. In: Runkler, T. A. (Hrsg.): *Data Analytics*. Springer Fachmedien Wiesbaden, Wiesbaden, 2020, S. 1–4
- [SS14] STOCKINGER, K.; STADELMANN, T.: Data Science für Lehre, Forschung und Praxis. *HMD Praxis der Wirtschaftsinformatik*, (51)4, 2014, S. 469–479
- [SSE+14] STEENSTRUP, K.; SALLAM, R.; ERIKSEN, L.; JACOBSON, S.: Industrial Analytics Revolutionizes Big Data in the Digital Business. <https://www.gartner.com/en/documents/2826118/industrial-analytics-revolutionizes-big-data-in-the-digi>, 2014
- [TB18] TIDD, J.; BESSANT, J. R.: *Managing innovation – Integrating technological, market and organizational change*. Wiley, Hoboken, NJ, 2018
- [TBD+10] TERZI, S.; BOURAS, A.; DUTTA, D.; GARETTI, M.; KIRITSIS, D.: Product lifecycle management – from its history to its new role. *International Journal of Product Lifecycle Management*, (4)4, 2010, S. 360–389
- [Tya03] TYAGI, S.: Using data analytics for greater profits. *Journal of Business Strategy*, (24)3, 2003, S. 12–14
- [UE16] ULRICH, K. T.; EPPINGER, S. D.: *Product design and development*. 6th Edition, McGraw-Hill, New York, NY, 2016
- [vOL12] VAN HORN, D.; OLEWNIK, A.; LEWIS, K.: Design Analytics: Capturing, Understanding, and Meeting Customer Needs Using Big Data. In: ASME 2012 (Hrsg.): *ASME 2012 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*. Volume 7. American Society of Mechanical Engineers (ASME), 12.-15. August 2012, Chicago, Illinois, USA, 2012, S. 863–875
- [WHT14] WUEST, T.; HRIBERNIK, K.; THOBEN, K.-D.: Capturing, Managing and Sharing Product Information along the Lifecycle for Design Improvement. In: Meyer, A.; Schirmeyer, R.; Vajna, S. (Eds.): *IDE Workshop – Proceedings of the 10th International Workshop on Integrated Design Engineering*, 10.-12. September 2014, Magdeburg/Gommern, Germany, Otto-von-Guericke-University Magdeburg, Magdeburg, 2014, S. 107-115
- [WSK+17] WILBERG, J.; SCHAFFER, F.; KANDBINDER, P.; HOLLAUER, C.; OMER, M.; LINDEMANN, U.: Data analytics in product development: Implications from expert interviews. In: IEEM 2017 (Hrsg.): *2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*. 10.-13. December 2017, Singapore, 2017, S. 818–822
- [WTH+17] WILBERG, J.; TRIEP, I.; HOLLAUER, C.; OMER, M.: Big Data in Product Development: Need for a Data Strategy. In: PICMET 2017 (Hrsg.): *2017 Portland International Conference on Management of Engineering and Technology (PICMET)*, 09.-13. July 2017, Portland, OR, IEEE, 2017, S. 1–10
- [XFR16] XU, Z.; FRANKWICK, G. L.; RAMIREZ, E.: Effects of big data analytics and traditional marketing analytics on new product success: A knowledge fusion perspective. *Journal of Business Research*, (69)5, 2016, S. 1562–1566

3 Referenzprozess für die Betriebsdaten-gestützte Produktplanung

Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler, Daniel Panick

Der Referenzprozess für die Betriebsdaten-gestützte Produktplanung stellt ein allgemeingültiges und in der Praxis erprobtes Vorgehen zur Planung, Vorbereitung, Durchführung und Verwertung von Betriebsdaten-Analysen in der strategischen Produktplanung dar. Entsprechend dieser Hauptaufgaben gliedert er sich in vier Hauptprozesse:

- (1) **Planung von Betriebsdaten-Analysen:** Im ersten Hauptprozess werden Erfolg versprechende Use Cases erarbeitet. Diese stellen alle wichtigen Informationen für die Betriebsdaten-Analyse bereit.
- (2) **Vorbereitung von Betriebsdaten-Analysen:** Der zweite Hauptprozess umfasst die Übersetzung des Use Cases in eine konkrete Data-Analytics-Aufgabenstellung und die Vorbereitung der Betriebsdaten.
- (3) **Durchführung von Betriebsdaten-Analysen:** Gegenstand des dritten Hauptprozesses ist die Betriebsdaten-Analyse selbst. Dabei werden Methoden und Modelle aus den Bereichen Machine Learning und Data Mining eingesetzt und evaluiert.
- (4) **Verwertung von Betriebsdaten-Analysen:** Im vierten Hauptprozess werden die Datenanalyse-Ergebnisse in die strategische Produktplanung zurückgeführt und ihre Auswirkungen auf die Produktstrategie untersucht.

Bild 3-1 gibt einen Überblick über den gesamten Referenzprozess. Die Hauptprozesse werden in den folgenden Abschnitten 3.1 bis 3.4 ausführlich vorgestellt.

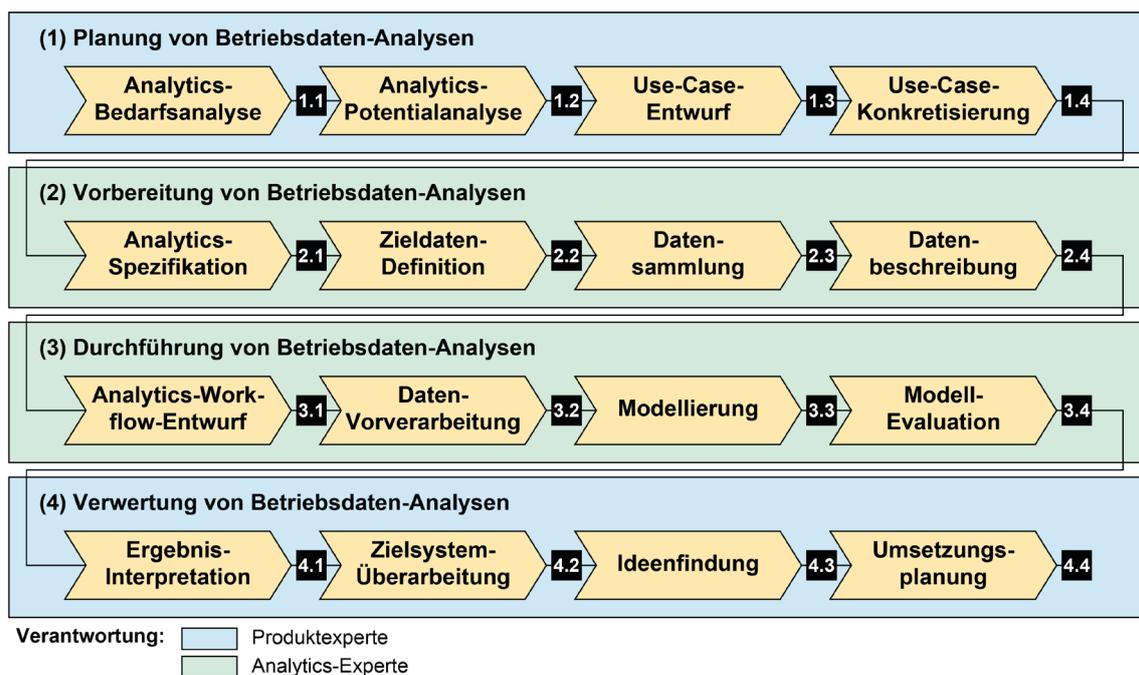


Bild 3-1: Referenzprozess für die Betriebsdaten-gestützte Produktplanung [MWP+22]

3.1 Planung von Betriebsdaten-Analysen

Der erste Hauptprozess des Referenzprozesses für die Betriebsdaten-gestützte Produktplanung umfasst die Planung von Betriebsdaten-Analysen. Ziel dieses Hauptprozesses ist ein Erfolg versprechender Use Case für das betrachtete Produkt und Unternehmen. Der Hauptprozess ist in vier Phasen unterteilt:

- (1) Im Rahmen der **Analytics-Bedarfsanalyse** werden Untersuchungsbedarfe ermittelt, denen in der strategischen Produktplanung eine hohe strategische Relevanz und eine hohe Unsicherheit zugeschrieben werden.
- (2) In der **Analytics-Potentialanalyse** werden die Stärken und Schwächen des Unternehmens hinsichtlich der Betriebsdaten-gestützten Produktplanung analysiert.
- (3) Der **Use-Case-Entwurf** umfasst die Festlegung der Ziele und Rahmenbedingungen des betrachteten Use Cases.
- (4) In der **Use-Case-Konkretisierung** werden relevante Fragen sowie benötigte Daten für den betrachteten Use Case ermittelt.

Bild 3-2 zeigt das methodische Vorgehen. Nachfolgend werden die Phasen vorgestellt.

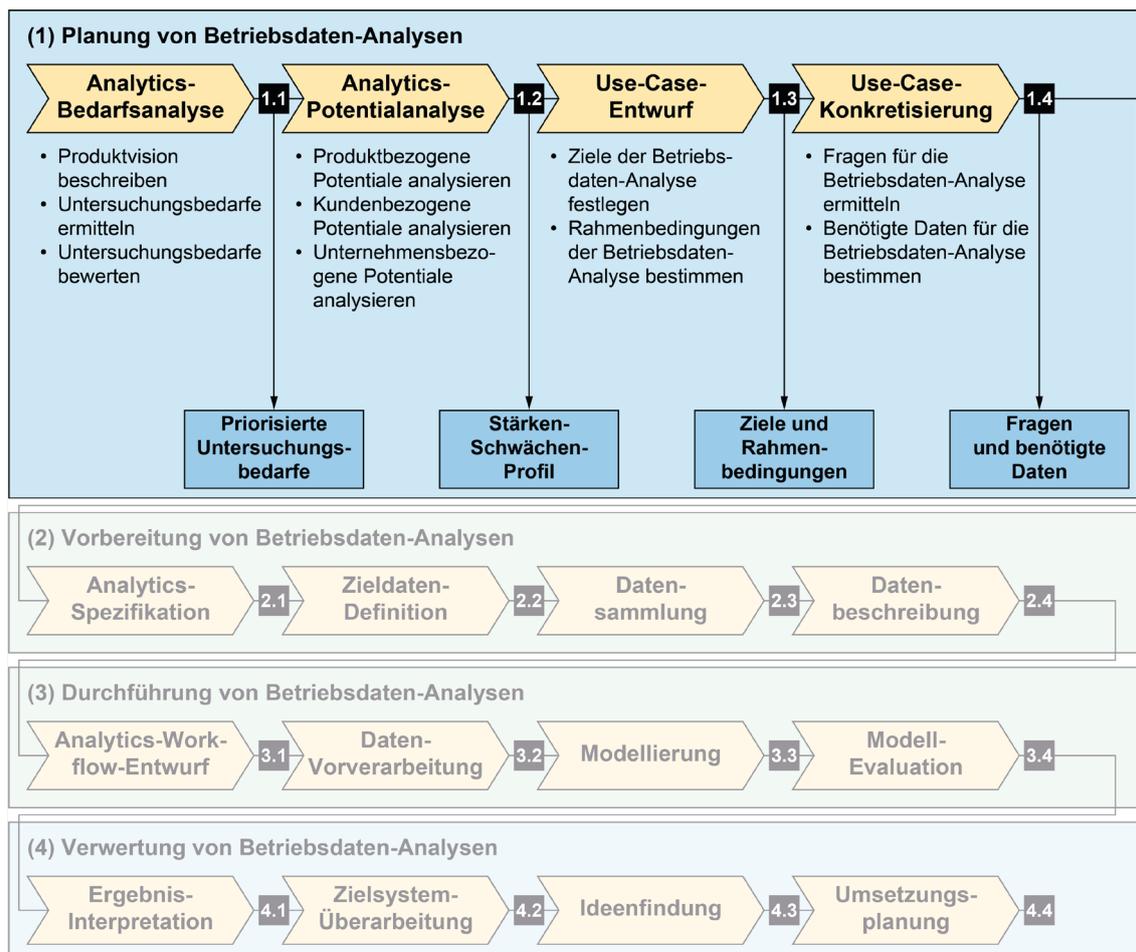


Bild 3-2: Vorgehen für die Planung von Betriebsdaten-Analysen in der strategischen Produktplanung

3.1.1 Analytics-Bedarfsanalyse

Die Analytics-Bedarfsanalyse stellt die erste Phase des Hauptprozesses „Planung von Betriebsdaten-Analysen“ dar. Ihr Ziel sind relevante Untersuchungsbedarfe für die Betriebsdaten-Analyse. Damit sucht sie Antworten auf die Leitfrage: *Was sollten wir mit Betriebsdaten-Analysen in der strategischen Produktplanung untersuchen?*

Den Ausgangspunkt der Analytics-Bedarfsanalyse bildet eine bereits definierte Produktvision, die ein angestrebtes Zielbild des Produkts in der Zukunft beschreibt. Erreicht werden soll diese Produktvision durch die Umsetzung der Produktstrategie. In Anlehnung an GAUSEMEIER ET AL. gibt die Produktstrategie die Richtung zur Erreichung der Produktvision vor und bündelt damit im Sinne von Leitplanken die Kräfte des Unternehmens, welche in Form von Zielen und Maßnahmen ausgedrückt werden [GP14]. Bild 3-3 visualisiert diese Metapher.

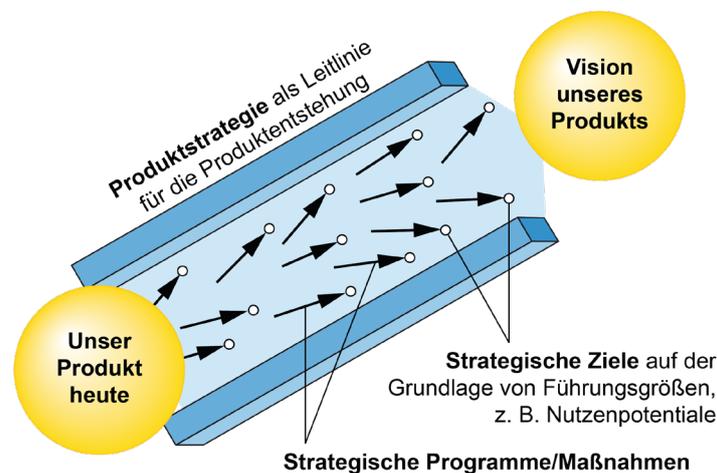


Bild 3-3: Die Produktstrategie als Weg zur Produktvision, dargestellt in Anlehnung an GAUSEMEIER und PLASS [GP14]

Wie das Bild zeigt, hängt die Produktstrategie zum einen von der Vision des Produkts ab. Ändert sich diese, muss die Produktstrategie angepasst werden. Zum anderen berücksichtigt sie aber auch die heutige Situation des Produkts, deren Abgleich mit der Vision ja erst den Handlungsbedarf und damit die Richtung der Produktstrategie offenlegt. Ist die Einschätzung der heutigen Situation des Produkts fehlerhaft, setzt die Produktstrategie an einem falschen Startpunkt an und gefährdet damit die Erreichung der Produktvision.

Im Rahmen der strategischen Produktplanung ist es folglich erforderlich, ein möglichst präzises Bild der heutigen Situation rund um das Produkt zu gewinnen. Dies betrifft die Leistung des Produkts im Betrieb, das Verhalten von Kunden und Nutzern und vieles mehr. Signifikante Erkenntnisse zu diesen Aspekten finden sich in den Betriebsdaten (vgl. Abschnitt 2.1.2) der Produkte im Betrieb wieder, die dafür jedoch erfasst, aggregiert und analysiert werden müssen. Da dies mit einem erheblichen Aufwand verbunden ist, werden in der Analytics-Bedarfsanalyse zunächst die relevanten Untersuchungsbedarfe

identifiziert. Die angestrebten Erkenntnisse sollen dabei stets einen Beitrag zur Realisierung der Produktvision liefern. Betriebsdaten-Analysen können so zum Beispiel aufdecken, wie nah das Produkt dieser Vision schon heute ist und was die wichtigsten Handlungsfelder sind. Die Konsequenzen fließen anschließend wieder in die Produktstrategie ein, zum Beispiel in Form neuer strategischer Ziele, Programme und Maßnahmen. Produktvision und -strategie werden somit in Teilen validiert.

Für einen möglichst großen Nutzen der Betriebsdaten-Analysen werden die Untersuchungsbedarfe aus der Produktvision ermittelt. Die Produktstrategie selbst bietet auch Anknüpfungspunkte, ist jedoch kleinteiliger aufgebaut, wodurch die Betriebsdaten-Analysen eine geringere Auswirkungsstärke entfalten würden. Um Untersuchungsbedarfe aus der Produktvision zu ermitteln, muss diese zunächst präzise erfasst werden. Dies kann zum Beispiel in Form eines Produktprofils geschehen. Dieses repräsentiert nach ALBERS ET AL. das Modell eines Nutzenbündels, das dessen angestrebten Anbieter-, Kunden- und Anwendernutzen für die Validierung zugänglich macht und dabei den Lösungsraum für die Gestaltung einer neuen Produktgeneration vorgibt [AHW+18].

Liegt noch kein derartiges Produktprofil vor, wird das Anbieter-, Kunden- und Anwender-Nutzenversprechen zum Beispiel mit dem Value Proposition Canvas nach OSTERWALDER ET AL. ermittelt. Dieses stellt im Original die Aufgaben, Gewinne und Probleme des Kunden dem Produkt mit seinen gewinnerzeugenden und problemlösenden Eigenschaften und Features gegenüber [OPB+14]. Um auch den Anbieter- und Anwendernutzen zu erfassen, können auf der rechten Seite statt des Kunden auch Anbieter und Anwender betrachtet werden. Das Nutzenversprechen auf Produktseite muss dann erneut passend dazu ermittelt werden. Im Anschluss liegen der angestrebte Anbieter-, Kunden- und Anwendernutzen zur Beschreibung der Produktvision vor. Bild 3-4 visualisiert das Prinzip.

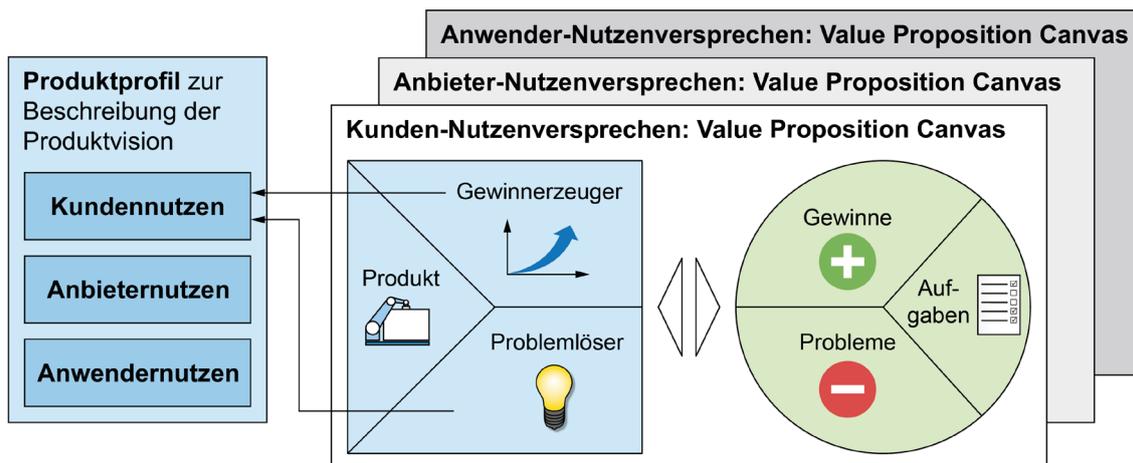


Bild 3-4: Ausprägung eines Produktprofils zur Beschreibung der Produktvision mit dem Value Proposition Canvas nach OSTERWALDER ET AL. [OPB+14]

Unterstützt werden kann die Ermittlung von Kunden- und Anwender-Nutzenversprechen zum Beispiel durch die generischen Nutzelemente nach ALMQUIST ET AL. [ASB16],

[ACS18]. Diese Elemente beschreiben, wie ein Produkt einem Kunden bzw. Anwender Nutzen stiften kann, z. B. durch die Reduktion von Aufwand. Nach einer initialen Begutachtung sind dazu Erfolg versprechende Nutzelemente auszuwählen und produktspezifisch auszugestalten.

Die spezifischen Nutzelemente, die den Kunden-, Anbieter- und Anwendernutzen im Produktprofil beschreiben, stellen potentielle Untersuchungsbedarfe für Betriebsdaten-Analysen dar. Dabei kann es sich zum Beispiel um die Produktqualität oder die Konfigurierbarkeit handeln. Um den konkreten Untersuchungsbedarf zu spezifizieren, werden die im Produktprofil aufgeführten Nutzelemente klassifiziert. Die Klassifizierung erfolgt im Vergleich zu den Produktprofilen der Vorgänger-Produktgeneration G_{n-1} , G_{n-2} etc., die sich gegenwärtig im Betrieb befinden. Neben den ermittelten Nutzelementen der Produktvision werden dabei auch noch die Nutzelemente ergänzt, welche Vorgänger-Produktgenerationen noch adressieren sollten, das in der Vision festgehaltene Produkt aber nicht mehr. Aufbauend auf den Zielsystem-Operationen von MEBOLDT können vier Klassen von Nutzelementen unterschieden werden [Meb08]:

- (1) **Übernommen:** Produktprofile von Vorgänger-Generationen besitzen das Nutzelement bereits. Das Nutzelement wird also übernommen.
- (2) **Verändert:** Produktprofile von Vorgänger-Generationen besitzen das Nutzelement in einer anderen Ausprägung. Das Nutzelement wird variiert.
- (3) **Ergänzt:** Produktprofile von Vorgänger-Generationen besitzen das Nutzelement noch nicht. Das Nutzelement wird ergänzt.
- (4) **Entfernt:** Produktprofile von Vorgänger-Generationen besitzen das Nutzelement, das Visions-Produktprofil jedoch nicht. Das Nutzelement wird entfernt.

Zur Priorisierung der Untersuchungsbedarfe sind die strategische Relevanz der Nutzelemente sowie die mit ihnen assoziierten Unsicherheiten zu bewerten. Das Ergebnis wird in einem Portfolio aufbereitet. Das Portfolio ist in drei Bereiche unterteilt. Im Bereich unten links werden Nutzelemente aufgeführt, die weder besonders relevant noch mit einer hohen Unsicherheit belegt sind. Der mittlere Bereich umfasst Nutzelemente, die entweder eine hohe Relevanz oder eine hohe Unsicherheit auszeichnet – aber nicht beides gleichzeitig. Die Nutzelemente mit der höchsten Priorität weist der Bereich oben rechts auf. Diese besitzen eine hohe Relevanz und gehen gleichzeitig mit hohen Unsicherheiten einher. Sie besitzen den größten Untersuchungsbedarf. Entsprechend ihrer Klassifizierung werden die Nutzelemente zudem eingefärbt. Sie stellen das Resultat der ersten Phase dar. Bild 3-5 zeigt das beschriebene Portfolio exemplarisch. So begründet sich der große Untersuchungsbedarf beim Nutzelement *Verfügbarkeit* zum Beispiel mit dessen hoher strategischen Relevanz sowie der hohen Unsicherheit, die mit dem Nutzelement und dessen Veränderung assoziiert wird.

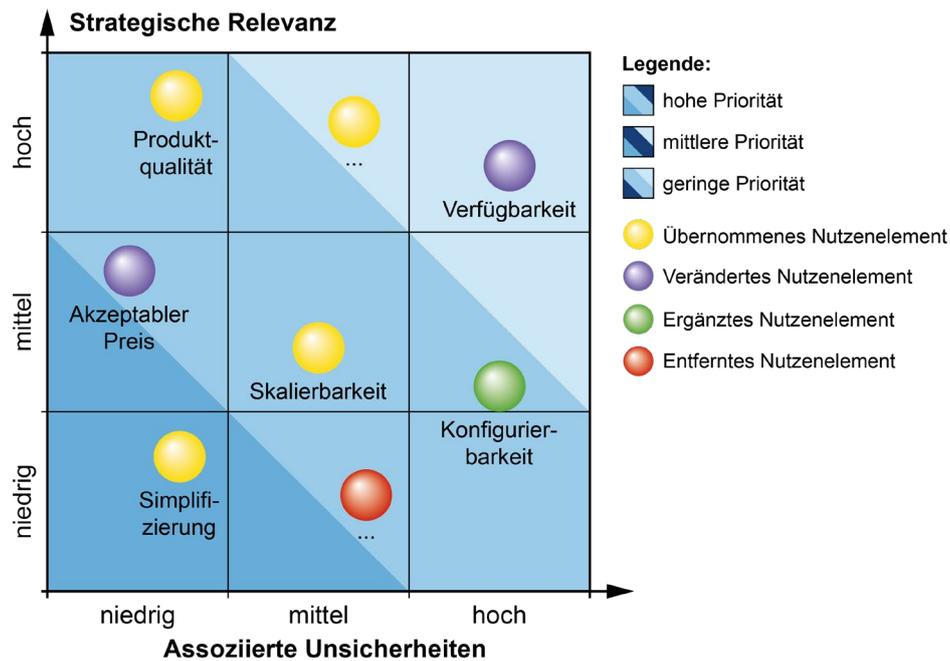


Bild 3-5: Portfolio zur Priorisierung der Untersuchungsbedarfe, überarbeitet nach [MWK+22]

3.1.2 Analytics-Potentialanalyse

Nach der Analytics-Bedarfsanalyse folgt die Analytics-Potentialanalyse als zweite Phase des Hauptprozesses „Planung von Betriebsdaten-Analysen“. Diese Analyse zielt auf die Stärken und Schwächen des betrachteten Unternehmens im Hinblick auf die Betriebsdaten-gestützte Produktplanung ab. Die Leitfrage lautet: *Welche Stärken und Schwächen besitzen wir im Hinblick auf die Durchführung von Betriebsdaten-Analysen in der strategischen Produktplanung?*

Die Analytics-Potentialanalyse gliedert sich in die drei Dimensionen *Produkt*, *Kunden* und *Unternehmen*. Jede dieser Dimensionen fasst Merkmale zusammen, deren Ausprägungen einen erheblichen Einfluss auf die Ausgestaltung der Betriebsdaten-gestützten Produktplanung der jeweiligen Unternehmen haben. Die Merkmale entstammen Literaturanalysen, Interviewstudien und der Zusammenarbeit mit den Anwenderunternehmen im Konsortialforschungsprojekt DizRuPt [MWK+21], [MFK+22a].

Die Dimension *Produkt* umfasst Merkmale, mit denen die Eignung des betrachteten Produkts für die Betriebsdaten-gestützte Produktplanung beurteilt werden kann. Beispielsweise ist es förderlich, wenn das betrachtete Produkt über zahlreiche Sensoren und Akteure verfügt. Hinderlich ist hingegen eine hohe Individualität der Produktinstanzen im Betrieb. Diese erschwert deren Vergleichbarkeit und damit die Generalisierbarkeit der Analysen. Bild 3-6 gibt einen Überblick über die Merkmale der Dimension *Produkt*.

Stärken-Schwächen-Analyse Dimension: Produkt	Beurteilung					Erläuterung
	--	-	o	+	++	
Nachvollziehbarkeit des Betriebsverhaltens		X				Sehr komplexe Maschine mit zahlreichen äußeren Einflussparametern
Anzahl an Sensoren und Aktoren				X		Zahlreiche Aggregate mit eigenen Aktoren und Sensoren
Dauer und Häufigkeit des Betriebs					X	Betrieb fast ausschließlich in zwei oder drei Schichten
Anzahl digital angebundener Produktinstanzen im Feld			X			In den letzten Jahren stark steigend
Vergleichbarkeit von Produktinstanzen und deren Daten im Feld	X					Sehr individuelle Maschinen mit generationsbedingt oft heterogenen Daten

Legende: -- sehr niedrig - eher niedrig o neutral + eher hoch ++ sehr hoch

Bild 3-6: Fragebogen für die Ermittlung von Stärken und Schwächen in der Dimension Produkt

Die Merkmale der Dimension *Kunden* adressieren die Bereitschaft und Fähigkeit der Kunden, Betriebsdaten an den Hersteller zurückzuspielen. Hier helfen zum Beispiel langjährige Kundenbeziehungen, die von einem hohen gegenseitigen Vertrauen geprägt sind. Ein Problem können hingegen ungeklärte rechtliche Fragestellungen zur Datenspeicherung und -analyse darstellen. In solch einer Situation scheuen es noch viele Unternehmen, Daten an Externe zu geben. In Bild 3-7 sind die Merkmale der Dimension *Kunden* aufgeführt.

Stärken-Schwächen-Analyse Dimension: Kunden	Beurteilung					Erläuterung
	--	-	o	+	++	
Bereitschaft zur Betriebsdaten-Bereitstellung		X				Überwiegend Skepsis, nur wenige offene Kunden
Qualität der Kundenbeziehungen					X	Langjährige und vertrauensvolle Partnerschaften mit zahlreichen Kunden
Vorhandensein digitaler Netzinfrastruktur für den Datenzugriff			X			In den letzten Jahren vermehrt aufgebaut
Vorhandensein rechtlicher Vereinbarungen zur Datenverwendung	X					Bisher nur vereinzelte Vereinbarungen zur akuten Problemanalyse

Legende: -- sehr niedrig - eher niedrig o neutral + eher hoch ++ sehr hoch

Bild 3-7: Fragebogen für die Ermittlung von Stärken und Schwächen in der Dimension Kunden

In der Dimension *Unternehmen* sind Merkmale gebündelt, aus denen auf die Fähigkeiten zur Datensammlung, -analyse und -verwertung des betrachteten Unternehmens geschlossen werden kann. Denn auch wenn die Produkte geeignet und die Kunden einer Datenanalyse zustimmen, ist es immer noch offen, ob es dem Unternehmen gelingt, Wert aus den Daten zu schöpfen. Umfangreiche Data-Analytics-Kompetenzen unterstützen dies zum Beispiel. Wenn jedoch andererseits die digitale Datendurchgängigkeit im Unternehmen nicht gewährleistet ist, droht der Prozess schnell zu stocken. Die Merkmale der Dimension *Unternehmen* stellt Bild 3-8 dar.

Stärken-Schwächen-Analyse Dimension: Unternehmen	Beurteilung					Erläuterung
	--	-	o	+	++	
Data-Analytics-Kompetenzen				X		In den letzten Jahren sukzessive aufgebaut
Digitale Datendurchgängigkeit		X				Noch zahlreiche „Daten-Inseln“ ohne Schnittstellen untereinander
Kooperation von Produkt- und Analytics-Experten				X		In den letzten Jahren in mehreren Projekten intensiv ausgebaut
Bereitwilligkeit einzelner Mitarbeiter & der gesamten Organisation			X			Grundsätzlich gegeben, aber Vorbehalte bei einzelnen Mitarbeitern vorhanden
Überblick über Produktinstanz-Konfigurationen im Feld	X					Kaum vorhanden, da PLM-System erst vor zwei Jahren eingeführt

Legende: -- sehr niedrig - eher niedrig o neutral + eher hoch ++ sehr hoch

Bild 3-8: Fragebogen für die Ermittlung von Stärken und Schwächen in der Dimension Unternehmen

Durchgeführt werden kann die Potentialanalyse im Rahmen von Interviews oder Workshops. In Interviews nehmen die Interviewpartner jeweils individuelle Beurteilungen der Merkmale vor. Workshops hingegen zeichnen sich durch den Diskurs der Teilnehmer aus. Die finale Beurteilung stellt dabei eine Konsensentscheidung der Workshopteilnehmer dar. Bei beiden Varianten ist wichtig, dass die Beurteilung ausführlich erläutert wird. Nur so können wichtige Implikationen für die anschließende Definition von Use Cases sowie Maßnahmen zur langfristigen Verbesserung des Stärken-Schwächen-Profiles identifiziert werden. Das Ergebnis der Analytics-Potentialanalyse ist ein unternehmensindividuelles Stärken-Schwächen-Profil, das neben den priorisierten Untersuchungsbedarfen aus der Analytics-Bedarfsanalyse die Grundlage für den Use-Case-Entwurf bildet.

3.1.3 Use-Case-Entwurf

Vor dem Hintergrund der identifizierten Analytics-Bedarfe und -Potentiale umfasst die dritte Phase des Hauptprozesses „Planung von Betriebsdaten-Analysen“ den Use-Case-Entwurf. Gegenstand ist die Festlegung von Zielen und Rahmenbedingungen für einen Erfolg versprechenden Use Case. Dies spiegelt sich in der Leitfrage wider: *Welche Ziele sollen wir mit unserem Use Case verfolgen und welche Rahmenbedingungen müssen wir dabei beachten?*

Die Ziele des Use Cases werden unter Berücksichtigung des Stärken-Schwächen-Profiles (vgl. Abschnitt 3.1.2) aus dem priorisierten Untersuchungsbedarf (vgl. Abschnitt 3.1.1) abgeleitet. Für eine ganzheitliche Betrachtung werden die übergeordneten Ziele der strategischen Produktplanung, das Thema des Use Cases, dessen Erfolgskriterien sowie die Systemgrenzen der Betriebsdaten-Analyse spezifiziert. In den übergeordneten Zielen der strategischen Produktplanung wird der betrachtete Untersuchungsbedarf weiter ausgeführt. Sie stellen den Kontext und die Begründung des Use Cases dar. Neben dem inhaltlichen Aspekt des zu untersuchenden Nutzelements bestimmt dessen Klassifizierung

die Ziele. Zum Beispiel bietet es sich bei übernommenen Nutzelementen an, die Erfüllung des Nutzelements im Betrieb zu überprüfen. Bei eliminierten Nutzelementen kann hingegen überprüft werden, ob Betriebsdaten die geplante Eliminierung unterstützen.

Um die übergeordneten Ziele der strategischen Produktplanung zu erreichen, werden diese auf den zu definierenden Use Case ausgeprägt. Dafür wird zunächst ein geeignetes Thema des Use Cases bestimmt. Dieses gibt an, wie die übergeordneten Ziele mit Betriebsdaten-Analysen unterstützt werden sollen. Zur Unterstützung dieses Schritts wurde untersucht, ob es allgemeingültige Zusammenhänge zwischen Nutzelementen und Use-Case-Themen gibt. Zur Systematisierung der Nutzelemente dienen die generischen Nutzelemente nach ALMQUIST ET AL. [ASB16], [ACS18]. Diese können als Elemente eines Nutzenbündels angesehen werden, mit dem gemäß Abschnitt 3.1.1 das angestrebte Produktprofil und damit die Produktvision beschrieben werden. Bild 3-9 zeigt die generischen Use-Case-Themen und ihre Verbindungen zu den generischen Nutzelemente [MPK+22]. Mit dieser Matrix kann systematisch von den betrachteten Nutzelementen auf sinnvolle Use-Case-Themen geschlossen werden.

Gegenüberstellung Use Cases & Nutzelemente		Nutzelemente																									
		Entspricht Spezifikationen	Akzeptabler Preis	Gesetzliche Vorschriften	Kostenreduktion	Produktqualität	Skalierbarkeit	Organisation	Simpleifizierung	Verbindung	Risikoreduktion	Flexibilität	Qualität der Komponenten	Zeiteinsparungen	Weniger Aufwand	Weniger Probleme	Information	Transparenz	Verfügbarkeit	Vielfalt/Auswahl	Konfigurierbarkeit	Reaktionsfähigkeit	Expertise	Kulturelle Eignung	Spaß und Vergünstigungen	Soziale Verantwortung	
Fragestellung: „Adressiert der gener. Use Case i (Zeile) das gener. Nutzelement j (Spalte)?“		Nr.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
Produkt	der Anforderungen	1	x	x			x	x				x		x													
	der Zuverlässigkeit	2			x	x	x					x		x		x	x	x		x							x
	der Fehler	3		x	x	x	x			x		x		x			x			x							
	des Verschleißes	4		x											x	x					x					x	x
	der Lösungsalternativen	5		x																						x	
	der Usability	6														x	x				x		x	x			
	der Belastung	7																									
Prozess	der Produktivität	8		x		x							x		x				x	x			x		x		
	der Prozessqualität	9													x									x			x
	der Ressourcen	10			x	x									x		x								x	x	x
	der Emissionen	11			x	x									x												
	der gesetzl. Konformität	12		x		x																					x
Kunde/Nutzer	der Produktnutzung	13						x	x				x	x												x	x
	der Featurenutzung	14		x		x	x			x																x	x
	der Produktvarianten	15						x																			
	des Nutzerverhaltens	16								x	x					x	x									x	x
	der Nutzerbedürfnisse	17														x						x	x		x		

Bild 3-9: Gegenüberstellung von generischen Use-Case-Themen und adressierten generischen Nutzelementen

Zur Messung des Erfolgs des Use Cases werden danach geeignete Erfolgskriterien definiert. Abschließend wird mit den Systemgrenzen festgelegt, was in die Betriebsdaten-Analyse inkludiert werden soll und was nicht. Bild 3-10 zeigt auf der linken Seite exemplarische Ausprägungen dieser Beschreibung der Use-Case-Ziele.

Im Anschluss an die Use-Case-Ziele werden dessen Rahmenbedingungen festgelegt. Konkret sind dabei Anforderungen, Grundannahmen, Restriktionen sowie Risiken der Betriebsdaten-Analyse festzuhalten. Die Anforderungen umfassen sowohl formale als auch inhaltliche Aspekte, die es bei der Betriebsdaten-Analyse zu beachten gilt. Mit den Grundannahmen werden Voraussetzungen beschrieben, welche die Grundlage für die Betriebsdaten-Analyse bilden. Treffen Grundannahmen nicht zu, hat dies einen erheblichen Einfluss auf die Datenanalyse-Ergebnisse und vermindert deren Aussagekraft drastisch. Die Restriktionen beschreiben die bekannten Einschränkungen, denen die Betriebsdaten-Analyse unterliegt. Mit den Risiken werden schließlich mögliche Gefährdungen der Betriebsdaten-Analyse umrissen, z. B. das Fehlen von Sensorik. Zugehörige Maßnahmen zur Risiko- und Auswirkungsreduktion runden diesen Punkt ab. Auf der rechten Seite von Bild 3-10 sind exemplarische Ausprägungen dieser Beschreibung der Use-Case-Rahmenbedingungen angegeben.

Ziele und Rahmenbedingungen des Use Cases: Ausfallanalyse	
Ziele	Rahmenbedingungen
<p>Übergeordnete Ziele der strat. Produktplanung</p> <ul style="list-style-type: none"> • Betrieb des Produkts soll weniger Aufwand erzeugen • Produkt soll "einfach laufen" und nicht ausfallen • ... 	<p>Anforderungen an die Betriebsdaten-Analyse</p> <ul style="list-style-type: none"> • Datenanalyse abgeschlossen bis Ende Juni 2023 • Hohe Ergebnisvalidität wegen strategischer Bedeutung • ...
<p>Thema des Use Cases</p> <ul style="list-style-type: none"> • Analyse der Zuverlässigkeit • Identifizierung regelmäßig ausfallender Elemente • ... 	<p>Grundannahmen der Betriebsdaten-Analyse</p> <ul style="list-style-type: none"> • Korrekte Installation aller Produktinstanzen • Nutzung geeigneter Werkzeuge • ...
<p>Erfolgskriterien des Use Cases</p> <ul style="list-style-type: none"> • Ermittlung des Ausfallrisikos aller Systemelemente • Identifizierung der häufigsten Ursachen • ... 	<p>Restriktionen der Betriebsdaten-Analyse</p> <ul style="list-style-type: none"> • Datenerhebung nur mit rechtlicher Vereinbarung • Sensornachrüstung nur in Einzelfällen möglich • ...
<p>Systemgrenzen der Betriebsdaten-Analyse</p> <ul style="list-style-type: none"> • Fokussierung auf in Deutschland installierte Instanzen • Vorgelagerte Prozesse werden nicht berücksichtigt • ... 	<p>Risiken der Betriebsdaten-Analyse</p> <ul style="list-style-type: none"> • Ablehnung der Datenbereitstellung durch Kunden • Kaum vergleichbare Bedingungen im Betriebsumfeld • ...

Bild 3-10: Exemplarische Ausprägungen von Zielen und Rahmenbedingungen eines Use Cases

Gemeinsam bilden Ziele und Rahmenbedingungen das Grundgerüst eines Use Cases der Betriebsdaten-gestützten Produktplanung und stellen damit das Resultat des Use-Case-Entwurfs dar. In der sich anschließenden letzten Phase des Planungsprozesses wird der Use Case weiter ausgearbeitet und konkretisiert.

3.1.4 Use-Case-Konkretisierung

Die vierte Phase des Hauptprozesses „Planung von Betriebsdaten-Analysen“ behandelt die Use-Case-Konkretisierung. In dieser Phase werden die zu beantwortenden Fragen und die zu untersuchenden Betriebsdaten erarbeitet. Dies ist wichtig, um Data Scientists den entworfenen Use Case und die damit verbundene Aufgabenstellung zugänglich zu machen. Die Leitfrage lautet: *Welche Fragen sollen beantwortet und welche Betriebsdaten analysiert werden?*

Zuerst werden die zu beantwortenden Fragen und die zu überprüfenden Hypothesen identifiziert. Zur methodischen Unterstützung dient ein Canvas, das zum Beispiel in einem Workshop ausgefüllt werden kann und in Bild 3-11 dargestellt ist. Es besitzt drei Felder: (1) *Was wissen wir?* (2) *Was vermuten wir?* (3) *Was wissen wir nicht?* Im ersten Feld wird eingetragen, was über den Use Case sicher bekannt ist. Dieses Feld stellt den Ausgangspunkt für die weiteren Felder dar und wird deshalb zuerst befüllt. Im zweiten Feld werden Vermutungen eingetragen, die den Use Case betreffen. Diese dienen als Aufhänger für die Erarbeitung von Fragen. Im dritten Feld werden Fragen gesammelt, die mit den Betriebsdaten beantwortet werden sollen. Sie können sich auf das vorhandene Wissen, die Vermutungen oder bewusste Wissenslücken beziehen. Um die Kreativität zu fördern, ist dieses Feld in Anlehnung an STEENSTRUP ET AL. in *deskriptive, diagnostische, prädiktive* und *präskriptive* Fragen unterteilt [SSE+14]. Orientierung und konkrete Beispiele für Fragen aus allen vier Klassen gewähren die generischen Use Cases nach MEYER ET AL. [MPK+22]. Für die Generierung von Fragen in einem Workshop empfiehlt sich die Methode des Question-Stormings, die an das klassische Brainstorming angelehnt ist, aber auf die Generierung von Fragen statt Antworten abzielt [Ber16]. Dabei werden zunächst so viele Fragen wie möglich generiert. Im Anschluss werden die Fragen bewertet und priorisiert. Für diesen Schritt kann aus zahlreichen etablierten Methoden gewählt werden. Eine Workshop-taugliche Methode ist zum Beispiel das Punktekleben.

Fragen-Canvas für den Use Case: Ausfallanalyse			
Was wissen wir? <ul style="list-style-type: none"> • Produkt fällt regelmäßig unerwartet aus • Nutzer sind zum Teil sehr unerfahren • ... 		Was vermuten wir? <ul style="list-style-type: none"> • Ausfälle geschehen in Folge falscher Bedienung • Überforderung der Nutzer mit den Einstellmöglichkeiten • ... 	
Was wissen wir nicht?			
Deskriptive Fragen <i>Welche Einstellungen wählen Nutzer besonders häufig aus?</i> ...	Diagnostische Fragen <i>In welchen Situationen wählen Nutzer welche Einstellungen?</i> ...	Prädiktive Fragen <i>Welche weiteren Einstellungen lassen Fehler erwarten?</i> ...	Präskriptive Fragen <i>Welche Einstellungen sollten in Zukunft nicht mehr erlaubt sein?</i> ...

Bild 3-11: Canvas zur Identifizierung relevanter Fragen für die Betriebsdaten-Analyse

Nach der Priorisierung der Fragen werden die zu analysierenden Daten abgeleitet. Als sehr nützlich hat sich dabei erwiesen, Umfeld- und Wirkstrukturmodelle des betrachteten

Produkts mit Hilfe der Spezifikationstechnik CONSENS aufzustellen [GDE+19]. Das Umfeldmodell beschreibt die Einbettung des Produkts in sein Umfeld und die zwischen Produkt und Umfeld bestehenden Wirkbeziehungen. Das Wirkstrukturmodell stellt hingegen die prinzipielle Wirkungsweise des Produkts dar. Dafür werden die Abhängigkeiten und Interaktionen seiner einzelnen Elemente visuell dargestellt [GDE+19]. Sowohl Umfeld- als auch Wirkstrukturmodell geben explizit Auskunft über Stoff-, Energie- und Informationsflüsse. Außerdem wird bereits ermittelt, ob die jeweiligen Flüsse gemessen werden, ob das Produkt also entsprechende Sensoren besitzt. Nach Aufstellung beider Modelle können die zur Beantwortung der Fragen erforderlichen Daten einfach aus den Modellen abgelesen werden. Bild 3-12 zeigt das Prinzip am Beispiel des Umfeldmodells einer Kaffeemaschine. Auch wenn zum Teil große Ähnlichkeiten zu erwarten sind, werden die erforderlichen Daten für jede Frage einzeln bestimmt. Andernfalls drohen zahlreiche Rückfragen im weiteren Verlauf der Betriebsdaten-Analyse. Das Wirkstrukturmodell wird analog aufgestellt, nur dass hier statt des Produkts und der Umfeldelemente die Bestandteile (Systemelemente) des Produkts und ihre Beziehungen modelliert werden.

Zu beantwortende Frage:

Wie bedienen Benutzer unsere Kaffeemaschine?

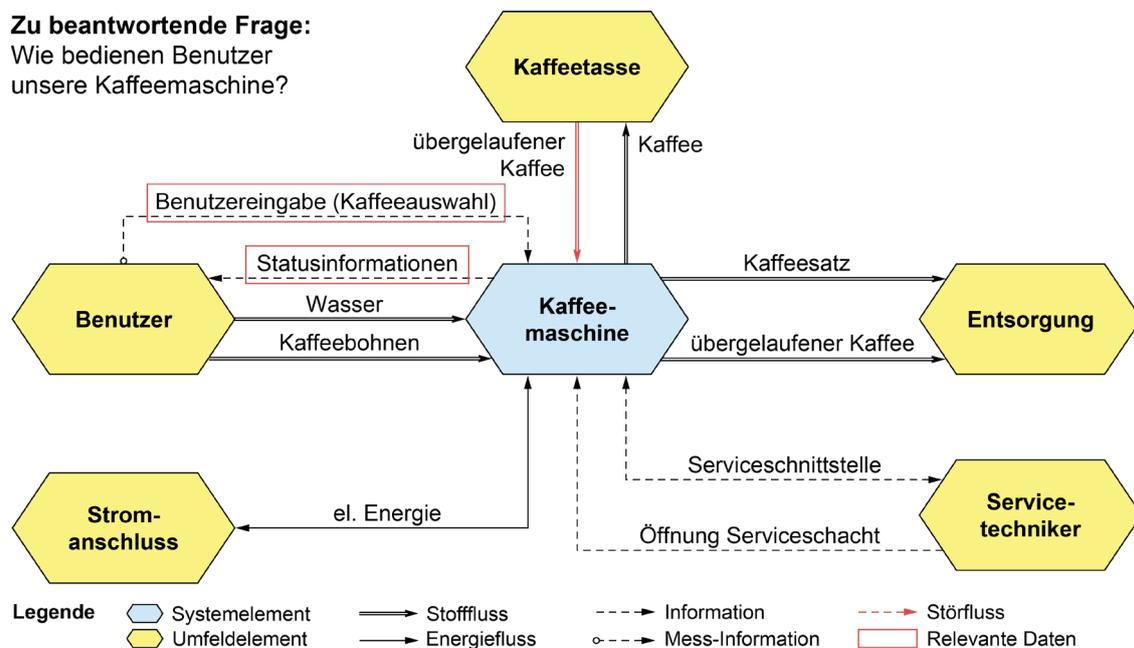


Bild 3-12: Ableitung relevanter Betriebsdaten am Beispiel eines CONSENS-Umfeldmodells; Umfeldmodell entnommen aus [GDE+19]

3.2 Vorbereitung von Betriebsdaten-Analysen

Der zweite Hauptprozess des Referenzprozesses für die Betriebsdaten-gestützte Produktplanung umfasst die Vorbereitung der Betriebsdaten-Analyse. Ziele dieses Hauptprozesses sind ein Plan für die Datenanalyse in Form einer technischen Data-Analytics-Aufgabenstellung und eine ausführliche Datenbeschreibung der notwendigen und akquirierten Daten. Der Prozess gliedert sich in vier Phasen:

- (1) In der **Analytics-Spezifikation** werden zunächst Analyseziele spezifiziert, d. h. die Anwendungsfälle werden in konkrete Datenanalyseziele umgewandelt. Fehlendes Domänenwissen muss erfasst werden, um relevante Variablen und adäquate Data-Analytics-Ansätze (z. B. Clustering) abzuleiten.
- (2) Im Rahmen der **Zieldaten-Definition** werden Daten und ihre Quellen spezifiziert sowie spez. Messungen oder Datenobjekte definiert. Dazu gehört die Transformation der def. physikalischen Größen in spez. Datenattribute im Zieldatensatz.
- (3) Die **Datensammlung** umfasst den Abgleich des Datenbedarfs mit den im Unternehmen vorhandenen Daten (Daten-Gap-Analyse). Sind die benötigten Daten nicht vorhanden, muss ein Akquise-Konzept entwickelt und umgesetzt werden.
- (4) In der **Datenbeschreibung** sind die gesammelten Daten zu verstehen und hinsichtlich ihrer Verarbeitungsmöglichkeiten zu analysieren. Hierfür wird zunächst eine erste Exploration durchgeführt sowie eine ganzheitliche Beschreibung der Daten mit relevanten Metadaten und eine Einordnung der Daten vorgenommen. Reicht die Datenqualität nicht aus, wird zum vorherigen Schritt zurückgekehrt.

In Bild 3-13 ist das methodische Vorgehen abgebildet.

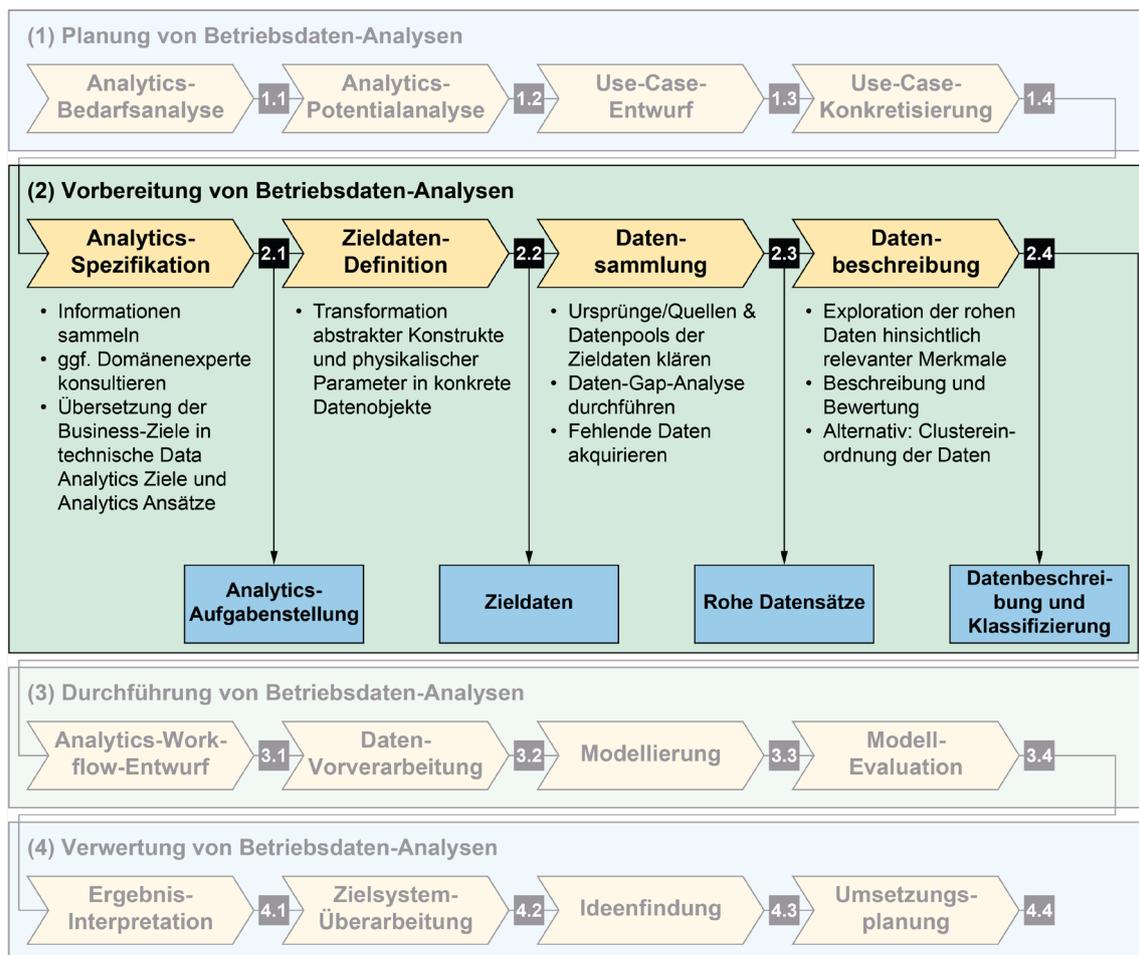


Bild 3-13: Vorgehen für die Vorbereitung der Betriebsdaten-Analysen in der strategischen Produktplanung

Im Folgenden werden die Phasen detailliert beschrieben und Hilfsmittel zur Umsetzung präsentiert. Als durchgängiges Hilfsmittel zur Dokumentation wird die Data-Analytics-Canvas empfohlen. Dabei handelt es sich um eine Spezifikationstechnik zur Beschreibung eines analytischen Anwendungsfalls, welche im nächsten Kapitel erläutert wird.

3.2.1 Analytics-Spezifikation

Ergebnis des letzten Schritts des ersten Hauptprozesses sind konkrete Use Cases. Diese befinden sich noch in der ‘‘Sprache’’ des Produktmanagers und enthalten erste wichtige Informationen, wie bspw. das Ziel und die Anforderungen, die auch für den Data Scientist wichtig sind. Ziel dieses Schrittes ist diese Use Cases in realisierbare Analytics-Aufgaben zu übersetzen, d. h. sie in eine Form zu bringen, die der Data Scientist mit Betriebsdaten umsetzen kann und die seine nächsten Tätigkeiten strukturiert. Das Standard-Vorgehensmodell für Data Mining ‘‘CRISP-DM’’ gibt hierzu ein Beispiel: Das Ziel ‘‘Steigerung von Katalog-Verkäufen an existierende Kunden’’ wird in das Analyse-Ziel ‘‘Vorhersage der Anzahl von gekauften Artikeln auf Basis der Kundenverkäufe der letzten drei Jahre, demographischer Informationen und dem Preis des Artikels’’ transformiert [CC00]. Daraus werden für den Data Scientist der Analyseansatz, die notwendigen Daten sowie Variablen ersichtlich. Um diese wesentlichen Elemente der Analytics-Aufgabe bestimmen zu können, gilt es die notwendigen Informationen und Parameter zusammenzutragen, die Aufschluss über die notwendigen Datenverarbeitungsschritte geben. Die Business-to-Analytics-Canvas (s. Bild 3-14) ist ein visuelles Kollaborationstool, mit dem der Data Scientist konzeptionell alle notwendigen Informationen sammeln und dadurch systematisch Analyseansatz und Variablen definieren kann [PME+22].

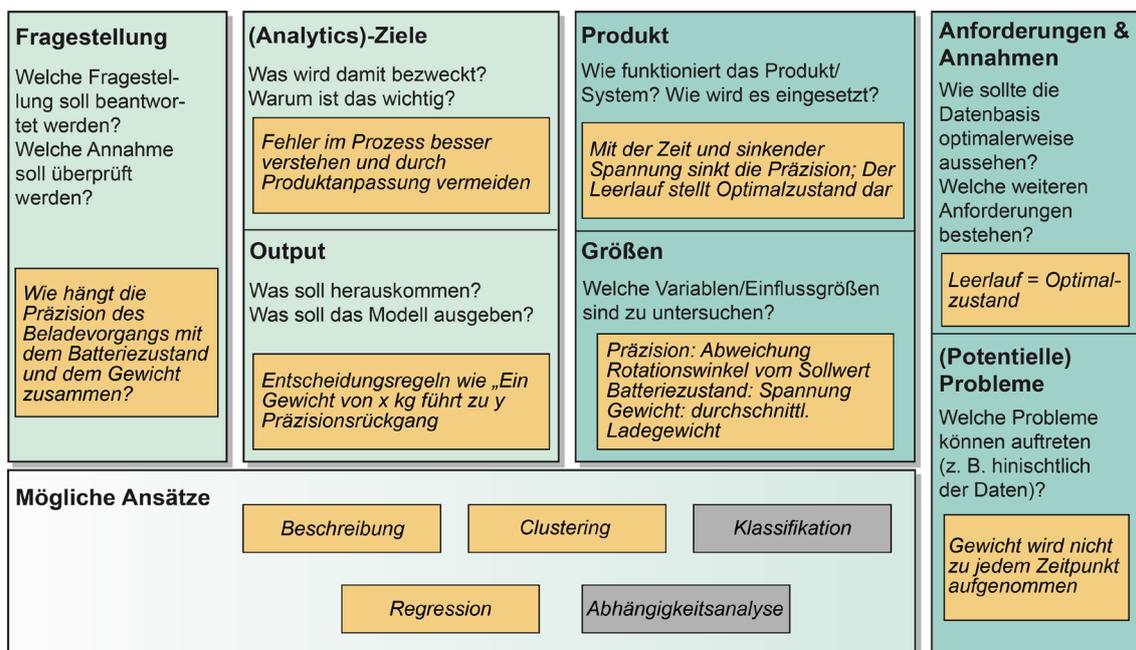


Bild 3-14: Business-to-Analytics-Canvas (B2A-Canvas) für die Übersetzung von Business-Use-Cases in Analytics-Aufgabenstellungen

Ziel des Canvas ist es reale Fragestellungen des Produktmanagers in die Data-Analytics-Terminologie zu „übersetzen“. Hierzu wird die passende Algorithmenklasse hergeleitet, die das Analytics-Problem am besten charakterisiert. Auf Grundlage bestehender Strukturierungen von Algorithmenklassen der Datenanalyse können Fragestellungen mindestens in eine der folgenden Klassen eingeteilt werden [PJR+00]:

- **Datenbeschreibung:** Die Datenbeschreibung zielt auf die prägnante Beschreibung von Merkmalen der Daten in elementarer und aggregierter Form ab. Dadurch erhält der Benutzer einen Überblick über die Struktur der Daten. Auch die Datenreduktion ist hier zu nennen. Sie dient dazu große Datensätze mit vielen Variablen anhand weniger prägnanter Merkmale zu beschreiben. Typischerweise ist die Datenbeschreibung ein Teilziel eines Data-Analytics-Use-Cases, meist in den frühen Phasen.
- **Klassifikation:** Klassifikation ist die Suche nach Mustern anhand eines Klassifikationsmerkmals, z. B. der Bauteilgröße. Ziel der Klassifikation ist das Erlernen der Zuordnung von Beobachtungen zu vorgegebenen Klassen, z. B. Bauteil defekt/nicht defekt. Diese Klassenlabel sind kategorische Werte und für jede Beobachtung bekannt. Klassifikationsmodelle werden meistens für prädiktive Modellierungen verwendet. Viele Data-Analytics-Probleme können in Klassifikationsprobleme transformiert werden, um Klassifikationsverfahren anwenden zu können.
- **Regression:** Die Regression ist der Klassifikation sehr ähnlich. Der einzige Unterschied besteht darin, dass ein Regressionsmodell versucht, eine kontinuierliche Größe vorherzusagen und nicht eine kategorische.
- **Clustering/Segmentierung:** Bei der Clusteranalyse werden Daten in sinnvolle oder nützliche Gruppen (Cluster) eingeteilt. Auf der einen Seite können Cluster für das Verständnis von Daten verwendet werden, indem automatisch potentielle Klassen gebildet werden (z. B. Segmentierung in kleinere Gruppen mit ähnlichen Merkmalen) und somit Objekte in den Daten strukturieren. Auf der anderen Seite können Cluster für die weitere Verwendung, d. h. als Grundlage für zusätzliche Datenanalysen, genutzt werden. In diesem Fall findet die Clusteranalyse die repräsentativsten Clusterprototypen (repräsentative Datenobjekte in den Clustern), z. B. durch Zusammenfassung von Daten oder Komprimierung. Diese Datenrepräsentationen können dann in ein weiteres Modell als Input gegeben werden.
- **Abhängigkeitsanalyse:** Bei der Abhängigkeitsanalyse geht es darum, ein Modell zu finden, das signifikante Abhängigkeiten (oder Assoziationen) zwischen Datenelementen oder Ereignissen beschreibt. Meist werden Abhängigkeiten zum Verständnis von gegenwärtigen Zusammenhängen verwendet, können aber auch für die prädiktive Modellierung verwendet werden. Vorteil gegenüber der Klassifikation ist, dass man eine Erklärung erhält und nicht nur einen vorhergesagten Wert. Assoziationen sind ein Spezialfall von Abhängigkeiten. Assoziationen beschreiben Affinitäten von Datenelementen (d. h. Datenelemente oder Ereignisse, die häufig zusammen auftreten). Zu unterscheiden sind hier die Begriffe und Ansätze

der Korrelation und Kausalität. Korrelation ist eine statistische Technik, die angibt, wie stark Paare von Variablen linear voneinander abhängen. Kausalität geht einen Schritt weiter und bedeutet, dass eine Veränderung in einer Variablen eine Veränderung in einer anderen Variablen verursacht; es besteht eine kausale Beziehung zwischen den Variablen. Im Allgemeinen reicht das Vorhandensein einer Korrelation nicht aus, um auf das Vorhandensein einer kausalen Beziehung zu schließen (d. h. eine Korrelation impliziert keine Kausalität).

Um die passende Algorithmenklasse zu bestimmen, werden die Felder des Canvas genutzt. Diese helfen, den Use Case technisch weiter zu spezifizieren. Die Fragen des Use Cases werden wieder aufgegriffen und im Falle einer technisch unscharfen Formulierung in eine analysierbare Form gebracht (z. B. „Ist die Prozessorleistung ausreichend groß dimensioniert?“ in „Wie viele Leistungspeaks liegen über der Lastgrenze?“). Dabei ist zu beachten, dass zur Beantwortung mancher Fragen oder Use Cases auch mehrere Analytics-Aufgaben notwendig sein können. Zur Gewährleistung der Vollständigkeit wird auch das wesentliche Ziel des Use Cases übernommen und ggf. nochmal geschärft. Data Scientist und Produktmanager stimmen den Output der Analyse genau ab. Hierzu gilt es transparent aufzuzeigen, welche Outputs mit welchen Algorithmenklassen möglich sind (typische Outputs von Segmentierungsverfahren sind z. B. ähnliche Objekte oder Gruppenzuweisungen). Die Bestimmung der geeigneten Klasse wird erreicht, indem die Fragestellung, das Ziel und der gewünschte Output zusammen betrachtet werden, um die geeignete Methodenklasse zu wählen.

Mit den Feldern *Produkt, Größen, Anforderungen & Annahmen* sowie *Probleme* sammelt der Data Scientist weitere wichtige Informationen. Dies dient einem besseren Produktverständnis, der Vertiefung einzelner Variablen sowie der Definition von wichtigen Störfaktoren und Anforderungen. Hinweise dazu stehen bereits in den Use Cases des Produktmanagers aus der Use-Case-Konkretisierung (vgl. Abschnitt 3.1.4), die übernommen und weiter ausdetailliert werden.

Zur Dokumentation der Ergebnisse der Phase Analytics-Spezifikation und der nächsten Phasen der Datenvorbereitung dient das Data-Analytics-Canvas (s. Bild 3-15) [KJR+18]. Das Data-Analytics-Canvas ist eine semiformale Spezifikationstechnik zur Beschreibung eines analytischen Anwendungsfalls, der notwendigen unternehmensweiten Dateninfrastruktur sowie Anforderungen für interdisziplinäre Domänen. Das Canvas unterstützt in der Phase der Identifikation und Planung von Analytics-Anwendungen und ermöglicht eine zielgerichtete Kommunikation der Projektbeteiligten. Das Canvas basiert auf dem 4-Ebenen-Modell zur Beschreibung eines Analytics-Use-Cases mit den Ebenen „Analytics-Use-Case“, „Datenanalyse“, „Datenpools“ und „Datenquellen“ (vgl. Abschnitt 2.1.3) [RKD17].

Die erste und zweite Ebene „Analytics-Use-Case“ und „Datenanalyse“ kann an dieser Stelle mit der Fragestellung, die aus Platzgründen ggf. zusammengefasst wird, und dem Analytics-Ansatz aus der B2A-Canvas befüllt werden.

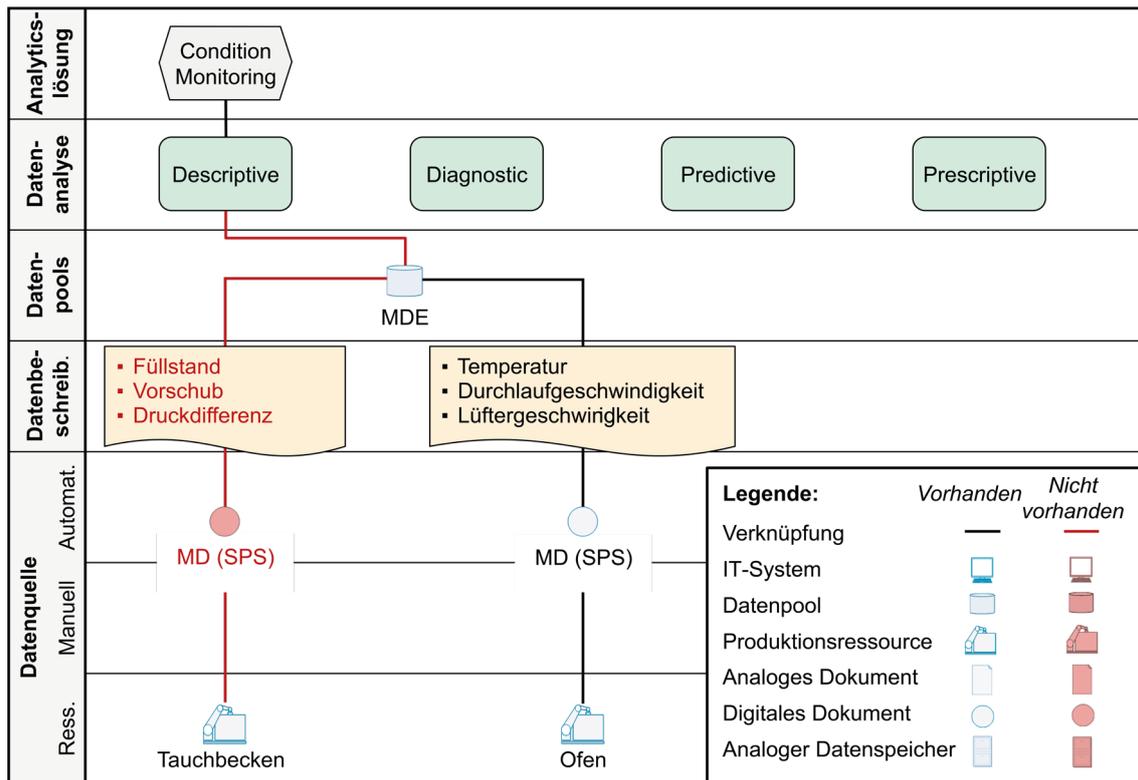


Bild 3-15: Data-Analytics-Canvas am Beispiel eines Condition-Monitoring-Anwendungsfall [KJR+18]

3.2.2 Zieldatendefinition

Im zweiten Schritt werden die Zieldaten definiert, was bereits durch die Größendefinition in der Business-to-Analytics-Canvas vorbereitet wurde. Häufig wird im Rahmen der Use-Case-Definition von Konstrukten oder Größen gesprochen, hinter denen bereits (Domänen-)Wissen steckt wie z. B. Maschinennutzung oder Nutzerverhalten. Dieses Konstrukt gilt es aber genauer zu verstehen und bis auf Datenebene herunterzubrechen.

Um die genannten Begrifflichkeiten besser zu verstehen, eignet sich das Modell der Wissenspyramide [AN55], welches in Bild 3-16 dargestellt ist. Dieses stellt die Entstehung von Wissen dar. Auf der untersten Ebene befinden sich die Daten, durch Syntaxregeln zu einer Aussage angeordnete Zeichen. Mittels Semantik werden Daten mit einer Bedeutung verknüpft, damit werden sie zu Informationen. Aus der Verknüpfung von Informationen mit Erfahrungen und Fachkenntnissen entsteht Wissen.

Der Data Scientist wird bei der zu analysierenden Fragestellung oftmals mit abstrakten Begriffen, die nicht direkt messbar und durch ein Datenobjekt abbildbar sind, oder physikalischen Parametern konfrontiert. Hierzu werden Indikatoren oder Informationen benötigt, die die erforderlichen Eigenschaften erheben. Zur Bestimmung der relevanten Indikatoren wird Domänenwissen benötigt.

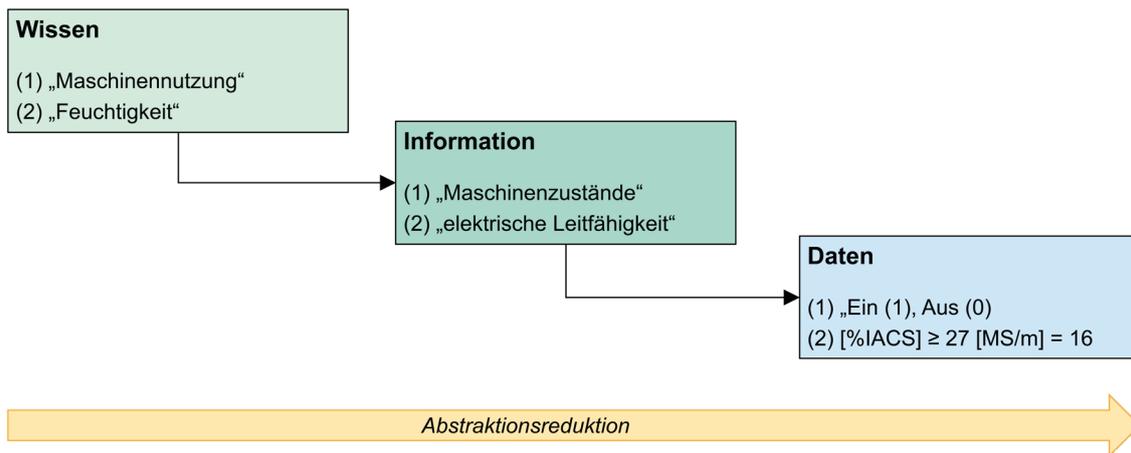


Bild 3-16: Modell der Wissenspyramide in Anlehnung an [AN55]

Um die Zieldaten bestmöglich zu definieren und greifbar zu machen, werden die in den Fragestellungen enthaltenen Größen in die zutreffende Ebene der Wissenspyramide eingeordnet. Mit den folgenden Leitfragen kann eine Konkretisierung auf die Datenebene erfolgen:

- **Wissen zu Information:** Durch welche messbaren Eigenschaften wird das Konstrukt beschrieben? Was ist an dem Konstrukt messbar?
- **Information zu Daten:** Welche Outputs ergibt eine Messung?

Zur genaueren Beschreibung können die Zieleigenschaften der Zieldaten vor dem Hintergrund des Use Cases und der Anforderungen bestimmt werden. Relevante Eigenschaften in diesem Kontext können die Folgenden sein:

- **Datenmenge:** Die Datenmenge spielt in der Datenanalyse eine große Rolle. Insbesondere Machine-Learning-Modelle, die aus den Daten lernen, benötigen ein Mindestmaß an Daten. Dabei ist zu beachten, dass die Daten die notwendigen Informationen enthalten müssen. Wenn beispielsweise erkannt werden soll, ob ein Fehlerfall vorliegt, dann müssen auch ausreichend Beispiele mit Fehlerfällen vorhanden sein.
- **Label:** Label, das sind die Kategorien von Daten, in die neue Datensätze eingeordnet werden sollen, sind im überwachten Machine Learning fundamental. Wenn also die Nutzung solcher Verfahren präferiert wird, müssen die Datensätze Label enthalten oder es muss die Bereitschaft zur nachträglichen Annotation der Daten bestehen, was häufig mit großem Aufwand verbunden ist.
- **Strukturierungsgrad:** Ob die Daten strukturiert (standardisiertes Format) oder auch unstrukturiert (ohne klassisches tabellarisches Format) sein sollen, hat einen großen Einfluss auf den Vorverarbeitungsaufwand. In der Regel benötigen unstrukturierte Daten deutlich mehr Vorverarbeitung, um sie in klassische statistische und maschinelle Lernverfahren integrieren zu können.
- **Frequenz:** Gerade im industriellen Kontext kann die Frequenz der Daten (Anzahl der Abtastungen) relevant sein, um alle notwendigen Informationen in den Daten

abbilden zu können. Während zum Beispiel ein Temperaturwert oftmals nur alle paar Minuten gespeichert werden braucht, kann eine wichtige Änderung der Motorvibrationen bei einer minutengenauen Abtastung verpasst werden.

3.2.3 Datensammlung

Wenn der Datenbedarf klar definiert ist, muss geprüft werden, ob dieser im Unternehmen abgedeckt ist oder notwendige Daten fehlen (Daten-Gap-Analyse). Der Data Scientist übernimmt diese Aufgabe zusammen mit den Domänenexperten und ggf. Datenverantwortlichen, um den notwendigen Überblick über die Datenlandschaft im Kontext des Produkts zu erhalten. Zur (gemeinsamen) Visualisierung und Ermittlung der Zusammenhänge zwischen Datenpunkten, Datenpools und Produkten werden die Ebenen „Datenquelle“, „Datenbeschreibung“ und „Datenpools“ der Data-Analytics-Canvas genutzt (s. Bild 3-17).

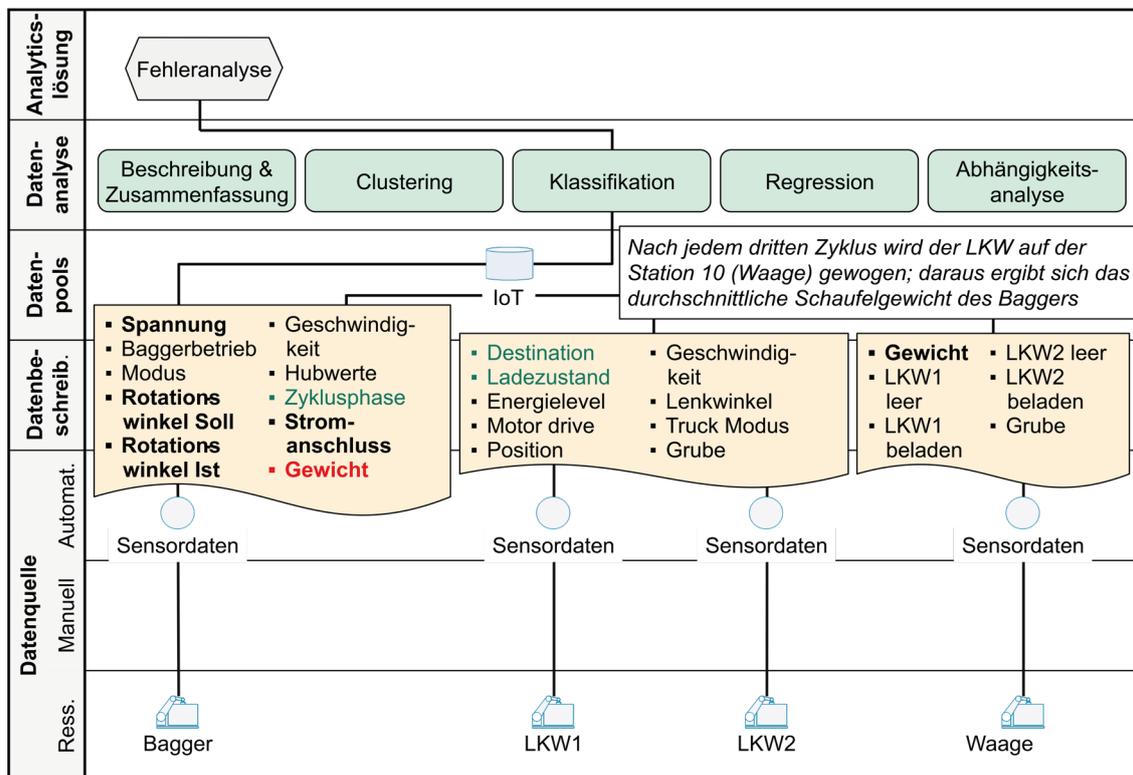


Bild 3-17: Beispiel einer ausgefüllten Data-Analytics-Canvas

Ausgehend von der Ebene „Datenbeschreibung“, die in der vorhergegangenen Phase bereits mit den Zieldaten befüllt wurde, werden als erstes die beteiligten „Ressourcen“ aufgeführt. Hier sind die Produkte bzw. Systeme zu nennen, welche die Betriebsdaten generieren. Falls weitere Datenursprünge hinzugezogen werden, z. B. externe Parameter wie Umgebungsbedingungen, können auch diese hier aufgeführt werden. Die Datenquellen können nun näher spezifiziert werden. In der strategischen Produktplanung werden hier in der Regel die Betriebsdatencluster aus Abschnitt 2.1.2 aufgeführt und ggf. noch weiter

expliziert (z. B. Sensordaten). Als Anknüpfungspunkt können die Wirkstrukturmodelle aus Abschnitt 3.1.4 dienen. Des Weiteren wird festgelegt, ob die Daten manuell oder automatisch von den Ressourcen gesammelt werden.

Für den Data Scientisten ist es wichtig zu wissen, wo diese Daten abliegen und wie sie zugänglich sind. Die „Datenpools“ führen oftmals Daten aus verschiedenen Ursprüngen zusammen. Das sind beispielsweise größere IT-Systeme, wie ERP-, MES- und CRM-Systeme oder auch große Data Warehouses¹ oder Data Lakes². Letztere integrieren sämtliche Quellen, wie z. B. eine IoT-(Cloud)-Plattform.

Nachdem die Datenquellen festgelegt sind, können die Variablen in der Datenbeschreibung um die Datenobjekte ergänzt werden, die unabhängig von den Zieldaten tatsächlich vorliegen. An dieser Stelle kann die Daten-Gap-Analyse durchgeführt werden, um festzustellen, ob Zieldaten fehlen. Ist dies der Fall, sollte zunächst geklärt werden, ob andere Datenpunkte den Bedarf abdecken. Auch eine Kombination von verschiedenen Datenpunkten kann einen einzelnen Datenpunkt ersetzen. Die benötigten und vorhandenen Daten werden in eine Tabelle überführt (s. Bild 3-18) und endgültig fehlende Daten in der Canvas markiert.

	Benötigt	Vorhanden	Gap	Fazit
<i>Abhängig (Target)</i>	Präzision	Abweichung Rotationswinkel (RW) Ist von RW Soll	-	Präzision durch Abweichung des RW gegeben
<i>Unabhängig</i>	Gewicht auf Baggerschaufel	Durchschnittliches Gewicht des LKWs für 3 Zyklen	Nur stark aggregierte Werte verfügbar	Regelmäßige Messung des Gewichts auf Schaufel notwendig
	Batteriezustand	Spannung		

Bild 3-18: Schema für die Daten-Gap-Analyse

Fehlende Daten müssen akquiriert werden. Dies erfolgt in sechs Schritten [PM22]. Ziel sind strukturierte, kontinuierliche Messdaten zu physikalischen Größen:

- (1) Im ersten Schritt wird die Sensornachrüstung spezifiziert, d. h. die Liste an fehlenden Daten aus der Daten-Gap-Analyse wird in ein Konzept überführt. Dazu werden den fehlenden Daten passende physikalische Messgrößen zugeordnet und überprüft, ob diese Messgrößen direkt durch einen Sensor gemessen werden können oder ob mehrere Sensoren zur indirekten Erfassung erforderlich sind (virtueller Sensor oder Softsensor). Schließlich ist der Ort der Messwertaufnahme zu definieren. Dazu wird das Produkt, welches eine Sensorik-Nachrüstung erhalten soll, unter Betrachtung der Aufnahme der Messgröße in seine einzelnen Kompo-

¹ Daten sind strukturiert in Datenbanken organisiert.

² Daten, auch unstrukturierte, lassen sich über viele unterschiedliche Storage-Lösungen verteilen und werden roh belassen.

- nennten unterteilt. Ziel ist es herauszufinden, an welcher Stelle des Produkts Vorgänge erfolgen, die eine Messwertaufnahme im Fokus der zuvor identifizierten Messgröße begründen.
- (2) Im zweiten Schritt wird das Messprinzip zur zugehörigen Messgröße ausgewählt. Bei vielen Messgrößen gibt es mehrere konkurrierende Wirkprinzipien, die jeweils spezifische Vor- und Nachteile aufweisen. Hier ist auch die erforderliche Leistung (z. B. Messbereich oder -genauigkeit) des Sensors anhand des zu erwartenden Verhaltens (z. B. dynamisch oder statisch) der Messgröße zu berücksichtigen. Auch sollte geprüft werden, ob die Messung direkt oder indirekt über andere Größen erfolgen kann. Daraus wiederum ergeben sich Implikationen für den Ort der Messung sowie die resultierenden Kosten.
 - (3) Anschließend werden Anforderungen an die Sensorik definiert. Aus dem vorherigen Schritt wird der Ort der Messwertaufnahme aufgegriffen und daraus eine geometrische Begrenzung sowie die in Frage kommenden Montagemöglichkeiten für den Sensor abgeleitet. Der Messort bedingt zudem die Umgebungsbedingungen, welchen der Sensor ausgesetzt ist; hier müssen ggf. Schutzmaßnahmen getroffen werden. Die Art der Schutzklasse kann dabei Einfluss auf die Kosten und die Energieversorgung haben. Zuletzt werden die Schnittstellen und Kommunikationsprotokolle für den nachzurüstenden Sensor untersucht. Hierfür wird die existierende IT-Infrastruktur sowie insbesondere die IoT-Plattform analysiert.
 - (4) Im vierten Schritt findet die Konkretisierung der Sensorlösung statt. Dazu wird ein Lastenheft erstellt, welches für Anfragen bei potentiellen Sensor-Herstellern herangezogen wird. In darauffolgenden Gesprächen mit den Anbietern werden konkrete Lösungsalternativen entwickelt, um die Nachrüstung vorzunehmen.
 - (5) Anschließend gilt es das vorteilhafteste Lösungskonzept auszuwählen. Hierzu wird eine Nutzwertanalyse anhand verschiedener Kriterien wie Kosten, Funktion, Komplexität und Störanfälligkeit durchgeführt, um einen Entscheidungsvorschlag zu erhalten.
 - (6) Das ausgewählte Lösungskonzept wird im letzten Schritt projiziert und umgesetzt. Aufgrund der diversen Aufgaben ist es zweckmäßig hierzu ein interdisziplinäres Projektteam, bestehend aus verschiedenen Fachbereichen, zusammenzustellen. Resultat dieses Schritts ist ein umgesetztes Sensorkonzept, welches die benötigten Daten liefert.

3.2.4 Datenbeschreibung

Im nächsten Schritt wird ein tiefergehendes Verständnis über die Daten aufgebaut. Dies ist für die Planung der nachfolgenden Schritte, insbesondere für das Design eines passenden Analytics-Workflows, wichtig – „*The most important knowledge a data mining engineer uses to judge workflows and models ‘ usefulness: understanding the meaning of the data*“ [KSB+10].

Das erforderliche Datenverständnis wird über die intrinsischen Merkmale der Daten und ihre Charakterisierung gewonnen. Die Datencharakterisierung liefert Hinweise zu den geeignetsten Verfahren. Sie beginnt mit dem Prozess des Verstehens, was in den Daten enthalten ist – das heißt, ob die Daten zuverlässig und für den Zweck geeignet sind [Pyl99]. Um die Art der Daten zu beschreiben, werden Merkmale benötigt. In diesem Zusammenhang wird von Metadaten gesprochen. Metadaten („Daten über Daten“) sind strukturierte Daten, die zur Beschreibung und Spezifizierung von Fakten über ein Informationsobjekt verwendet werden. Metadaten definieren also Datenmerkmale. Es gibt verschiedene Merkmale, wie z. B. die häufig genannten Big-Data-Charakteristika („V’s of Big Data“), z. B. Volume, Velocity und Variety [Zha16].

Analyserelevante, allgemeine und individuelle Merkmale für Betriebsdaten sowie mögliche Indikatoren zur besseren Zuordnung von Variablen sind in der Taxonomie der Datenmerkmale zusammengefasst (siehe Bild 3-19) [PEM+22]. Allgemeine Merkmale sind die Folgenden:

- **Datensatzgruppe:** Varietät, d. h. der Art des Datensatzes und des Grades der Strukturierung
- **Dimensionalität:** Menge der Attribute
- **Spärlichkeit:** Prozentsatz der Zellen in einer Datenbanktabelle, die nicht ausgefüllt sind
- **Dichte:** Prozentsatz der Zellen in einer Datenbanktabelle, die ausgefüllt sind
- **Komplexität:** Kompliziertheit z. B. durch Abhängigkeiten in den Daten
- **Volumen:** Datenmenge

Individuelle Merkmale sind Datenqualitätsprobleme, wie Ausreißer und fehlende Werte, und der Variablentyp der Daten (z. B. kategorial oder numerisch).

		Dimension	Ausprägungen		Indikator (beispielhaft)	
Datenmerkmale (allgemein)	Datensatz- gruppe (Typ)	Tabelle- rische Daten (strukturiert)	Relationale Daten (z. B. Tabelle, Datenmatrix)		Feste Anzahl an Datenfeldern, keine Verknüpfung zwischen Einträgen	
			Graphenbasierte Daten		Verbindungen, Objektbeziehungen	
			Sequentielle Transaktionsdaten	Itemsets + Zeitangabe (keine bestimmte Frequenz)		
				Sequenzdaten	Geordnet ohne Zeitstempel	
			Zeitreihen- daten	Signal	Messbare physikalische Parameter	
				Kein Signal	Messungen über die Zeit im Allgemeinen	
			Räumliche Daten		Positionen, Bereiche	
			Text	Unstrukturiert		Fehlendes Format (keine Trennungen der Informationen)
				Halbstrukturiert		Tags, Metadaten
			Bild		Metadaten	
	Video		Metadaten			
	Dimen- sionalität	Niedrigdimensional		Deutlich weniger Features als Beobachtungen		
		Hochdimensional		Mehr Features als Beobachtungen, > 100 Features		
	Spärlich		Viele Lücken in den Daten,			

Bild 3-19: Ausschnitt der Datentaxonomie für die Betriebsdaten-gestützte Produktplanung

Bei der Aufgabe der Datenbeschreibung unterstützt ein Fragebogen (s. Bild 3-20), mit dem eine Bestimmung der wichtigen Merkmale erfolgen kann, um im nächsten Schritt, dem Analytics-Workflow-Design, passende Analytics-Verfahren über Charakteristika/Tags abzuleiten.

Charakteristik/ Tags	Frage	Ja	Nein	Un- klar	Bemer- kung
(Sehr) strukturierte Daten	Liegen die Daten als Tabelle oder Matrix mit einer feststehenden Anzahl an Datenfelder vor, ohne Verbindung zwischen den Einträgen?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Sequentielle Transaktionsdaten	Liegen die Daten als Transaktionen mit einem Zeitbezug vor, die z. B. Events zu einem Zeitpunkt beschreiben?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Sequenzdaten	Sind die Daten geordnet, aber ohne Zeitstempel?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Zeitreihen	Liegen die Daten als Messungen über die Zeit vor?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Signale	Liegen die Daten als gemessene physikalische Parameter über die Zeit vor?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Räumliche Daten	Enthalten die Daten eine Information über einen Standort?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Unstrukturierter Text	Liegen die Daten im Textformat vor und enthalten sie Tags und Metadaten?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Semistrukturierter Text	Liegen die Daten im Textformat vor und enthalten sie Tags und Metadaten?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Niedrig dimensional	Haben die Daten deutlich weniger Features/Attribute als Beobachtungen?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Hoch dimensional	Haben die Daten mehr Features als Beobachtungen?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Dünnbesetzte Daten	Haben die Daten viele Lücken in Form von Nullen, sind z. B. nur Veränderungen sichtbar?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Dichte Daten	Enthalten die Daten Werte, die sich kontinuierlich ändern?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
(Auto-)Korrelation	Haben die Datenpunkte eine hohe Abhängigkeit zu ihren Nachbarpunkten?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Geringe Datenmengen	Haben die Daten eher 100 Zeilen (pro Tag)?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Normale Datenmengen	Haben die Daten eher 1000 Zeilen?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
Riesige Datenmengen	Haben die Daten eher 100.000 Zeilen?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

Bild 3-20: Fragebogen zur Bestimmung der Merkmale der Betriebsdaten

Neben einer individuellen Datenbeschreibung anhand der aufgeführten Merkmale bzw. des Fragebogens sieht das Instrumentarium auch eine einfache und schnelle Beschreibung

durch Einordnung in eins von fünf definierten Datenclustern (s. Bild 3-21). Diese umfassen Kombinationen von allgemeinen Betriebsdatenmerkmalen, die typischerweise zusammen auftreten.

	Cluster				
	Sequenzielle dünnbesetzte Echtzeitdaten	Stark strukturierte historische Daten	Gemischt-strukturierte, hochdimensionale Echtzeitdaten	Echtzeit-Zeitreihendaten	Text Daten
Beispiele	Sensordaten, Steuersignale für einzelne Aktoren, Hardware-Zustände, Software-Status, Warnmeldungen	Hardware-Konfigurationen, Werkseinstellungen, Warnungen, Beschwerden, Bewertungen	Aktordaten, Aktivitätsdaten	Vibrationsdaten, Hardwarestand, Softwarezustand, Produktionsmenge, Arbeitslast, Laufzeit, Energieverbrauch	Lizenzen, Protokolle (Wartung, Instandhaltung)
Datensatzgruppe	Zeitreihen, sequenzielle Transaktionsdaten	Strukturiert (relationales Datenbankschema)	Gemischt	Zeitreihen (Signale)	Semi-strukturierter bis unstrukturierter Text
Echtzeitverhalten	Echtzeit	Nicht Echtzeit	Echtzeit	Echtzeit	Nicht Echtzeit
Menge	Kleine bis mittlere Datenmenge	Kleine Datenmengen	Mittlere bis große Datenmengen	Kleine Datenmengen	Kleine Datenmengen
Komplexität	Unkorreliert	Unkorreliert	Unkorreliert	(Auto-)korreliert	Unkorreliert
Dimensionalität	Niedrigdimensional	Niedrigdimensional	Hochdimensional	Niedrigdimensional	Niedrigdimensional
Verteilung	Dünnbesetzt	Dünnbesetzt	Dicht	Dicht	Dünnbesetzt

Bild 3-21: Datencluster zur schnellen Beschreibung von Betriebsdaten

Falls Merkmale, insb. Datenqualitätsmerkmale, nur unzureichend ausgeprägt sind, muss der Data Scientist zurück in die Datensammlung und die benötigten Daten neu erheben oder Alternativen finden. Das gilt auch, wenn die Anforderungen in Form der Zieleigenschaften aus der „Zieldatendefinition“ (vgl. Abschnitt 3.2.2) nicht erfüllt werden können. Zur Vervollständigung können die wichtigsten Merkmale mit in die Datenbeschreibung in der Data-Analytics-Canvas ergänzt werden.

Neben dem Überblick über die vorhandenen Daten konnte in dieser Phase Verständnis über die Daten aufgebaut werden. Das stellt eine gute Vorbereitung und damit Ausgangspunkt für die Durchführung der Betriebsdaten-Analyse dar.

3.3 Durchführung von Betriebsdaten-Analysen

Im Rahmen des dritten Hauptprozesses wird der Analytics-Workflow entworfen und umgesetzt. Das Vorgehen umfasst vier Phasen:

- (1) Im **Analytics-Workflow-Entwurf** werden Vorverarbeitungs- und Modellierungstechniken ausgewählt und zu Konzepten für die Analyse-Workflows kombiniert.
- (2) In der **Daten-Vorverarbeitung** werden die Workflow-Schritte Datensäuberung, Datentransformation und Feature Engineering mit Hilfe von Tools und Bibliotheken umgesetzt.
- (3) In der **Modellierung** wird das Modell des Workflows mit geeigneten Werkzeugen, wie Machine-Learning-Frameworks, Data-Analytics-Suites und Auto-ML-Ansätzen realisiert.
- (4) Die **Modell-Evaluation** dient der Bewertung der Modelle anhand von geeigneten Metriken, wie der Klassifikationsgenauigkeit. Die Modelle, die am besten anhand der Metriken performen, z. B. die höchste Genauigkeit haben, werden mit den dazugehörigen Ergebnissen ausgewählt.

Bild 3-22 stellt das Vorgehen dar, das nachfolgend detailliert beschrieben wird.

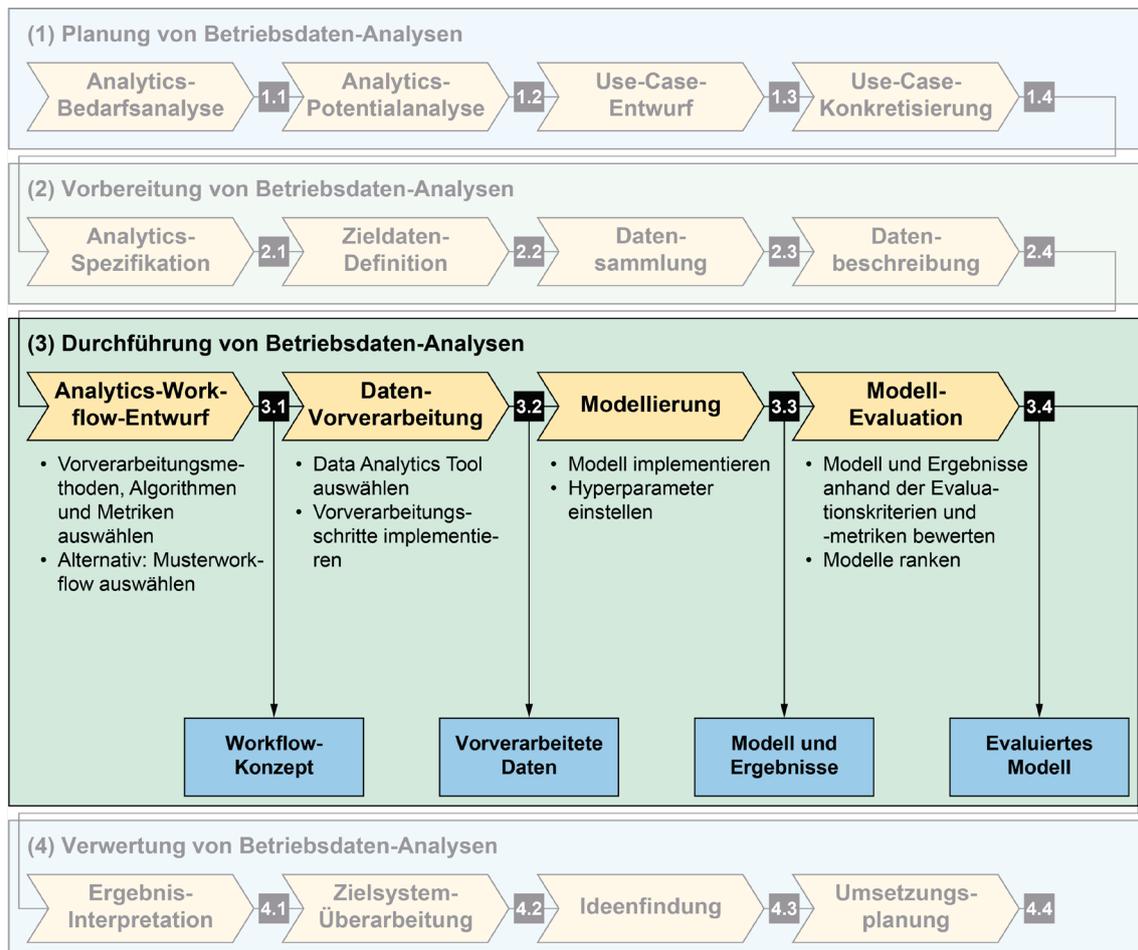


Bild 3-22: Vorgehen für die Durchführung von Betriebsdaten-Analysen in der strategischen Produktplanung

3.3.1 Analytics-Workflow-Entwurf

Der erste Schritt ist der Entwurf des Analytics-Workflows. Unter einem Analytics-Workflow wird die gesamte Kette an Vorverarbeitungsmethoden, Algorithmen und Nachbearbeitungsoperatoren verstanden. Sie werden im Folgenden Analytics-Bausteine genannt. In Bild 3-23 ist ein exemplarischer Workflow dargestellt. Er besteht aus den allgemeingültigen Bausteinen für die Datensäuberung, Datentransformation und Datenkonstruktion (Feature Engineering) innerhalb der Vorverarbeitung sowie den Bausteinen für die Modellierung und Evaluierung. Die Besonderheit der Betriebsdaten-gestützten Produktplanung liegt in dem letzten Schritt des Workflows, der Aggregation der Modellergebnisse für die einzelnen Produktinstanzen durch statistische Maße, wie z. B. Mittelwerte.

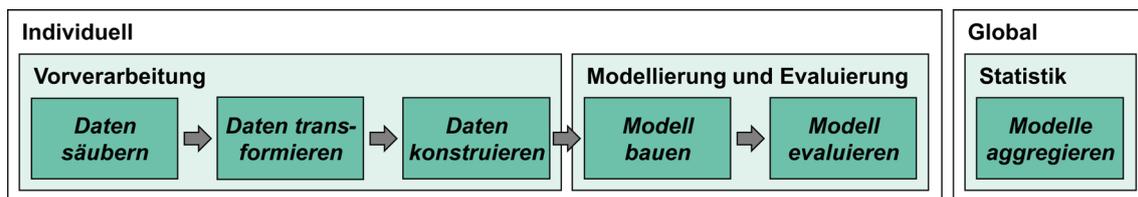


Bild 3-23: Typischer Analytics-Workflow für die strategische Produktplanung

Die Auswahl der passenden Bausteine ist auch bekannt unter dem Problem der Algorithmenauswahl [Ric76]. In der Regel gibt es mehrere Techniken für dieselbe Problemart. Einige Modellierungstechniken benötigen spezifische Datenformate oder haben bestimmte Modellannahmen, die es bei der Auswahl der passenden Methoden für die vorliegenden Daten und das Analytics-Ziel zu berücksichtigen gilt. Um die Bausteine eines Workflows bestimmen zu können, sind mehrere Faktoren zu berücksichtigen. Zum einen ist das Data-Analytics-Problem von Bedeutung, welches die Datenanalyseziele berücksichtigt und einen Lösungsraum an potentiellen Verfahren zur Lösung des Problems vorgibt. Zum anderen beeinflussen die Input-Daten die Auswahl und das Ergebnis. Die meisten Modelle haben Annahmen oder Einschränkungen, die die Daten erfüllen müssen, wie zum Beispiel, dass keine Autokorrelation¹ vorliegt oder dass keine Werte fehlen dürfen. Im Fall von Einschränkungen hinsichtlich des Input-Formats können Vorverarbeitungsmethoden eingesetzt werden, um die Daten bestmöglich für das Modell vorzubereiten. Als dritter Faktor sind zusätzliche (Qualitäts-)Anforderungen und persönliche Präferenzen seitens der Anwender zu nennen, welche den Lösungsraum weiter einschränken, wie z. B. Nachvollziehbarkeit, Know-how-Erfordernis und Skalierbarkeit.

In Bild 3-24 sind die wesentlichen Faktoren und Hilfsmittel aufgeführt, die bei der Auswahl der Analytics-Bausteine eine Rolle spielen. Sobald eine Entscheidung für ein Modell gefallen ist, können auf Basis der Dateneigenschaften die Bausteine der Vorverarbeitung definiert werden. Datenqualitätsprobleme sind insbesondere für die Datenbereinigung wichtig, so können fehlende Werte in den Daten zum Beispiel mit Hilfe von Vor-

¹ Autokorrelation beschreibt die Korrelation einer Funktion oder eines Signals mit sich selbst zu einem früheren Zeitpunkt.

verarbeitungsmethoden wie Imputation oder Interpolation behandelt werden. Die passenden Methoden für die Datentransformation ergeben sich auf der einen Seite aus den vorliegenden Variablentypen der Daten und auf der anderen Seite durch das Input-Format, welches die ausgewählten Modelle erfordern.

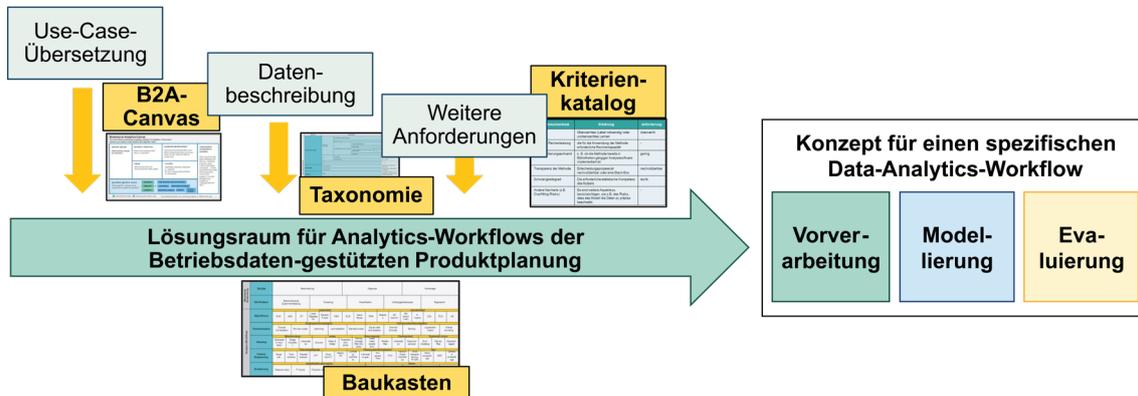


Bild 3-24: Auswahlfaktoren für Analytics-Bausteine im Analytics-Workflow

Um diese nicht trivialen Auswahlsschritte zu vereinfachen, können sowohl Hilfsmittel aus den vorhergehenden Schritten als auch neue Hilfsmittel eingesetzt werden. Nachfolgend werden alle Hilfsmittel aufgeführt:

- Der Baukasten für Analytics-Bausteine (s. Bild 3-25) strukturiert Data-Analytics-Methoden, die häufig in der Betriebsdaten-gestützten Produktplanung eingesetzt werden, entlang des Data-Analytics-Workflows in Form eines morphologischen Kastens. Er gibt damit einen begrenzten Lösungsraum vor, der anhand der genannten Auswahlfaktoren weiter verkleinert werden kann.
- Die Business-to-Analytics-Canvas aus Abschnitt 3.2.1 liefert das Data-Analytics-Problem, gibt also vor, ob ein Klassifikations-, Regressions-, Clustering- oder Abhängigkeitsmodell benötigt wird.
- Mit Hilfe des Kriterienkatalogs (s. Bild 3-26) können zusätzliche Anforderungen an die Analyse bestimmt werden. Dieser zeigt relevante Eigenschaften von Algorithmen auf, an die nach Präferenz und Ziel des Use Cases Anforderungen gestellt werden können.
- Die Datenbeschreibung ist bereits in Abschnitt 3.2.4 mit Hilfe des Fragebogens geschehen. Damit sind die analyserelevanten Eigenschaften bekannt.

DA-Ziel	Beschreibung		Diagnose		Vorhersage	
	Beschreibung & Zusammenfassung	Clustering	Klassifikation	Regression	Abhängigkeitsanalyse	
DA-Problem	Überwacht		Überwacht		Überwacht	
	SVM	ANN	DT	Lineare Regression	Random Forest	Naive Bayes
Algorithmus	Skalieren und Normalisierung		Skalieren und Normalisierung		Transformation / Diskretisierung	
	Z-Score Normalisierung	Min-Max skallerer	Stammform-reduktion	Lemmatisierung	Standard skallerer	Gleichbreite Diskretisierung
Transformation	Fehlende Werte		Ausreißer		Rauschen (Signale)	
	Multi-variante Imputation	Einzelne Imputation	Interpolation	Z-Score	Mittelwert & Standard-abweichung	Schwelle (Box plots)
Bereinigung	Zeitreihe / Signale		Merkmauswahl / -reduktion		Text	
	Steigungs-rechner	Zeitfenster	Wavelet Analyse	FFT	Kurze Zeit FT	Markow FE
Feature Engineering	Klassifikationsansatz		Klassifikationsansatz		Andere	
	Genauigkeit	F1 - Score	Präzision und Wieder-erinnerung	ROC	AUC	Quadratischer Mittelwert Fehler
Evaluierung	Support und Konfidenz		Externe Validierung		Intercluster-dichte	
	Support und Konfidenz	Quadratischer Mittelwert Fehler	AUC	ROC	AUC	Quadratischer Mittelwert Fehler
(Business-) Anwendung	Analyse-Workflow					

Bild 3-25: Analytics-Baukasten für die Betriebsdaten-gestützte Produktplanung

Algorithmusmerkmal	Erklärung	Anforderung
Lernart	Überwachtes (Label notenwendig) oder unüberwachtes Lernen	Überwacht
Benötigte Rechenleistung	Erforderliche Rechenkapazität für die Anwendung der Methode	-
Implementierungsaufwand	Vorhandensein einer Implementierung der Methode in Bibliotheken gängiger Analysesoftware	Bibliothek vorhanden
Transparenz der Methode	Nachvollziehbarer Entscheidungsprozess oder Black-Box	Nachvollziehbares Modell
Schwierigkeitsgrad	Erforderliche statistische Kompetenz des Nutzers	Geringe Kompetenz erforderlich
Andere Nachteile (z. B. Overfitting-Risiko)	Berücksichtigung weiterer Aspekte, wie z. B. das Risiko, dass das Modell die Daten zu präzise beschreibt	-

Bild 3-26: Kriterienkatalog zur Auswahl von Bausteinen des Analytics-Workflows

3.3.2 Datenvorverarbeitung

Um Data-Analytics-Workflows zu implementieren, existiert eine Vielzahl an verschiedenen Tools. Grundsätzlich kann zwischen Frameworks für eine Programmiersprache (z. B. Python) und großen Enterprise-ML-Suites unterschieden werden. Wir gehen im Folgenden insbesondere auf Lösungen in der Programmiersprache Python ein, da Python zahlreiche Frameworks und Bibliotheken bietet, die Data-Analytics- und Machine-Learning-Funktionen umsetzen. Sie sind häufig Open Source, d. h. frei verfügbar, und können entlang der gesamten Analytics-Prozesskette für jeden Workflowschritt eingesetzt werden: von der Vorverarbeitung (Cleaning, Transformation, Feature Engineering), über die eigentliche Modellierung und Evaluierung bis hin zum Deployment. Im Folgenden werden die Vorverarbeitungsschritte kurz erläutert und einige häufig genutzte Bibliotheken für die Vorverarbeitungsschritte aufgeführt.

Cleaning: Die Datenbereinigung ist einer der wichtigsten Schritte in einem Analytics-Projekt. Dazu gehören viele Schritte wie das Entfernen von Nullwerten, die Behandlung von Ausreißern, die Codierung von Merkmalen und vieles mehr. Die Datenbereinigung ist sehr zeitaufwändig und erfordert viel Geduld. Meist verbringen Data Scientists einen beträchtlichen Teil ihrer Zeit mit der Datenbereinigung. Für diese Aufgabe kann beispielsweise die Bibliothek NUMPY verwendet werden, welche den Standard für Vektorisierungs- und Indizierungskonzepte darstellt und mehrdimensionale Arrays verarbeitet. Für Datenanalyse und -manipulation in Python ist PANDAS eine der am häufigsten verwendeten Bibliotheken, die von NUMPY unterstützt wird. Dank der großen Flexibilität bei der Bearbeitung von Data Frames ist sie für die Analyse, Bearbeitung und Bereinigung von Daten gut einsetzbar. DATACLEANER ist eine Drittanbieter-Bibliothek, die auf dem Data Frame von PANDAS aufbaut. DATACLEANER verfügt über eine Methode, die einige typische Datenbereinigungsfunktionen kombiniert und automatisiert, wodurch viel

Zeit und Mühe eingespart werden kann. SCIPY bietet eine Sammlung solcher Open-Source-Bibliotheken, darunter NUMPY, MATPLOTLIB und PANDAS. Als Gesamtsystem enthält SCIPY unter anderem Module für die numerische Optimierung, lineare Algebra, numerische Integration, Interpolation, Fast-Fourier-Transformation, Signalverarbeitung, Bildverarbeitung, numerische Integration gewöhnlicher Differentialgleichungen und symbolische Mathematik.

Transformation: Gegenstand der Transformation ist es, die Daten in ein durch maschinelles Lernen erfassbares Format umzuwandeln. Alle Analytics- und ML-Algorithmen basieren auf Mathematik, also müssen alle Daten in ein numerisches Format konvertiert werden. Eine häufige Transformation ist die Umwandlung von kategorischen Werten in numerische Werte, da nur wenige Algorithmen direkt mit Kategorien umgehen können. Einige der Data-Cleaning-Bibliotheken können auch für die Datentransformation verwendet werden. Insbesondere PANDAS macht Transformationen und Manipulationen einfach und intuitiv. Es enthält ein leistungsstarkes Data-Frame-Objekt, das für die Datentransformation verwendet werden kann. NUMPY stellt ein effizientes Array-Objekt zur Verfügung, das nützlich für diese Aufgabe ist. SCIPY enthält mehrere numerische Routinen, die für die Datentransformation geeignet sind.

Feature Engineering: Feature Engineering ist eine Aktivität zur Erstellung neuer Merkmale aus dem vorhandenen Datensatz. Diese Arbeit erleichtern u. a. FEATURETOOLS, ein Paket zur Automatisierung des Feature-Engineering-Prozesses, das von ALTERYX entwickelt wurde. FEATURE-ENGINE ist ein weiteres Paket für Feature Engineering und Auswahlverfahren. TSFRESH ist ein Python-Paket für das Feature Engineering von Zeitserien und sequentiellen Daten. Es ist mit der SCIKIT-LEARN-Methode kompatibel, sodass es in den Workflow eingebunden werden kann.

Bei der Auswahl von Frameworks und Tools sind grundsätzlich folgende Aspekte relevant:

Umgang mit Datentypen: Tools unterscheiden sich auch hinsichtlich der Input-Formate, mit denen sie umgehen können. Einige Tools und Bibliotheken sind beispielsweise auf die Verarbeitung von Zeitserien spezialisiert, andere auf Textdaten.

User-Interface: Data-Analytics-Tools mit grafischen Benutzeroberflächen zielen in der Regel darauf ab, Benutzern mit geringen Programmierkenntnissen zu helfen, Datenanalyseverfahren mit Hilfe von grafischen Benutzeroberflächenelementen umzusetzen. Wenn keine grafische Benutzeroberfläche verfügbar ist, erfolgt die Anwendung mit Hilfe gängiger Entwicklungsumgebungen wie z. B. JUPYTER oder PYCHARM unter Verwendung von Quellcode.

Lizenz: Die von ML-Tools vertretenen Lizenzen lassen sich grob in Open-Source-Lizenzen und kommerzielle Lizenzen unterteilen. Letztere sind häufiger bei den ML-Suiten zu finden, da hier insbesondere Anwender angesprochen werden, die einen engeren Bezug zu Geschäftsprozessen aufweisen und über weniger Programmierkenntnisse verfügen. So

werden oft eine stabile Umgebung und eine benutzerfreundliche grafische Oberfläche für standardisierte Arbeitsprozesse gewünscht. Für allgemeine ML-Bibliotheken und Frameworks werden häufig Open-Source-Lizenzen vergeben, die sich auch durch einen Beitrag der offenen Community auszeichnen. Der Open-Source-Charakter ermöglicht auch Kombinationen mehrerer Tools, sodass andere Data-Science-Tools aus vorgelagerten Arbeitsschritten in Kombination genutzt werden können. Der Einsatz von Open-Source-Technologien fördert somit Eigenentwicklungen, die sich durch einen erhöhten Programmieraufwand auszeichnen und damit Programmierkenntnisse erfordern.

Tooltyp: Hierbei lassen sich drei verschiedene Typen unterscheiden: (1) Stand-Alone-Anwendungen, (2) Webtools und (3) Erweiterungen. Eine Stand-Alone-Anwendung ist eine Anwendung, die lokal auf dem Gerät läuft und nichts anderes benötigt, um zu funktionieren. Die gesamte Logik ist in die Anwendung integriert, sodass sie weder eine Internetverbindung noch andere installierte Dienste benötigt. Eigenständige Anwendungen werden verwendet, wenn keine Internetverbindung für die Hauptfunktionen der App erforderlich ist. Alle Daten können lokal auf dem Gerät gespeichert werden. Für einige geschäftliche Aufgaben kann diese Art von Anwendungen sehr wertvoll sein, da sie oft sehr spezifische Probleme lösen können und außerdem den Datenzugriff für Dritte sehr schwierig machen. Derzeit gewinnen Anwendungen des zweiten Typs (Webanwendungen) an Beliebtheit. Die Cloud-Lösungen werden den Stand-Alone-Lösungen vorgezogen, da von jedem Gerät aus auf sie zugegriffen werden kann. Es ist keine Installation erforderlich und Daten werden sicher gespeichert. Zu den Erweiterungen (3) zählen Plugins und Bibliotheken. Plugins sind Softwareerweiterungen, mit denen Benutzer Softwareanwendungen, Webbrowser und Webinhalte individuell anpassen können. Software-Plugins nutzen die bestehende Programmcode-Struktur, um bestimmte Funktionen bereitzustellen.

Auto-ML-Verfügbarkeit: Auto-ML-Funktionen erfreuen sich immer größerer Beliebtheit. Sie unterstützen den Anwender/Entwickler vor allem in der Modellierungsphase, z. B. bei der Hyperparameteroptimierung oder der Modellauswahl. Die Werkzeuge lassen sich hinsichtlich der Verfügbarkeit von Auto-ML unterscheiden. Entweder verfügen sie über eigene Funktionen, die die Automatisierung von Pipelineschritten ermöglichen, es sind Erweiterungen verfügbar oder es fehlen Auto-ML-Möglichkeiten.

Anbindung an Datenquellen: Ein Kriterium für die Auswahl geeigneter Werkzeuge sind auch die Anbindungsmöglichkeiten an Datenquellen über Konnektoren. Ein Datenkonnektor ist definiert als ein Prozess, der Daten aus einem Quellspeicher entnimmt und in einen Zielspeicher schreibt. Relevant ist beispielsweise, ob ein Tool eine Verbindung zu Datenbanken (bspw. zu einer SQL-Datenbank) herstellen kann oder ob es möglich ist, eine Datei über das Dateisystem zu laden und zu speichern. Mittlerweile ist für viele auch interessant, ob ein Konnektor zu Cloud-Systemen wie AWS (Amazon Web Services) vorhanden ist.

Performance: Die Tools lassen sich nach ihrer Leistung unterscheiden. Es gibt rechenintensive KI-Methoden wie Deep Learning und/oder große Datensätze, die leistungsstarke Tools erfordern können. Solche High-Performance-Tools erlauben die Verarbeitung großer Datenmengen, die ein herkömmlicher Computer nicht mehr bewältigen kann. Die Nutzung von modernsten Technologien wie GPU, Verbindungsleitungen mit geringer Latenz und paralleler Verarbeitung macht das möglich. Andere Tools, die solche Technologien nicht einsetzen, können unter Umständen große Datenmengen nicht oder nur sehr langsam verarbeiten.

3.3.3 Modellierung

In der Modellierungsphase werden die Modellierungstechniken, die im Workflow-Entwurf ausgewählt wurden, angewandt und ihre Parameter werden auf optimale Werte kalibriert. Sehr viele Tools und Bibliotheken unterstützen diese Phase, einige beliebte Kern-Frameworks werden nachfolgend kurz vorgestellt.

Scikit-learn: SCIKIT-LEARN ist eine Open-Source Python-Bibliothek, die eine Reihe von Algorithmen für maschinelles Lernen, Vorverarbeitung, Kreuzvalidierung und Visualisierung über eine einheitliche Schnittstelle implementiert. Sie bietet verschiedene Klassifizierungs-, Regressions- und Clustering-Algorithmen, darunter Support Vector Machines, Random Forests, Gradient Boosting, k-means, etc.

Tensorflow: Hinter TENSORFLOW steckt eine Open-Source-Softwarebibliothek für numerische Hochleistungsberechnungen. Ihre flexible Architektur ermöglicht den einfachen Einsatz von Berechnungen auf einer Vielzahl von Plattformen (CPUs, GPUs, TPUs) und von Desktops über Server-Cluster bis hin zu mobilen und Edge-Geräten. Ursprünglich wurde es von Forschern und Ingenieuren des Google Brain-Teams innerhalb der KI-Organisation von Google entwickelt. Es verfügt über eine starke Unterstützung für maschinelles Lernen und Deep Learning, und der flexible numerische Berechnungskern wird in vielen anderen wissenschaftlichen Bereichen eingesetzt.

Gensim: Die Open-Source-Bibliothek GENSIM steht für die unüberwachte Themenmodellierung, die Indizierung von Dokumenten, die Suche nach Ähnlichkeit und andere Funktionen zur Verarbeitung natürlicher Sprache unter Verwendung maschineller Lernverfahren. GENSIM ist darauf ausgelegt, große Textsammlungen mit Hilfe von Daten-Streaming und inkrementellen Online-Algorithmen zu verarbeiten, was es von den meisten anderen Softwarepaketen für maschinelles Lernen unterscheidet, die nur auf In-Memory-Verarbeitung abzielen. Es enthält Implementierungen von *fastText*, *word2vec* und *doc2vec* Algorithmen, *Latent semantic analysis*, *latent Dirichlet allocation* und *tf-idf*.

H2O: H2O ist eine Open-Source-Software vom Unternehmen *H2O.ai* für Big-Data-Analysen. H2O implementiert Algorithmen aus dem Bereich Statistik, Data Mining und maschinelles Lernen (generalisierte Lineare Modelle, K-Means, Random Forest, Gradient Boosting und Deep Learning). Die Software basiert auf dem Hadoop-Distributed-File-

System, sodass ein Performance-Gewinn gegenüber anderen Analysewerkzeugen erzielt wird. Das Tool kann grafisch über einen Webbrowser bedient werden oder über Schnittstellen mit R, Python, Apache Hadoop und Spark genutzt werden. Mit Hilfe der REST-API kann H2O auch von Microsoft Excel oder RStudio aus bedient werden.

Darüber hinaus können sogenannte Data-Analytics-Suites eingesetzt werden, welche in der Regel den gesamten Prozess von der Vorverarbeitung bis zur Modellevaluierung unterstützen. RAPIDMINER ist eine Entwicklungsumgebung für die Datenanalyse, die als Open-Source-Software an der Universität Dortmund entstanden ist und heute zu den Marktführern gehört. Sie bietet Unterstützung für alle Phasen des Data-Mining-Prozesses, von der Datenvorbereitung über die Anwendung einer breiten Palette von Algorithmen für maschinelles Lernen, Modellvalidierung und Optimierung bis hin zur Visualisierung der Ergebnisse. Das Werkzeug bietet eine reichhaltige grafische Benutzeroberfläche, die die Entwicklung komplexer Arbeitsabläufe, sogenannter „Prozesse“, ermöglicht. Jeder Prozess ist so konzipiert, dass er einen oder mehrere so genannter „Operatoren“ verbindet, während ein Operator für die Ausführung einer einzelnen Aufgabe vorgesehen ist. Sie bietet spezialisierte Oberflächen für Endanwender ohne Programmierkenntnisse, die die Verfahren des maschinellen Lernens einsetzen wollen. Ein RAPIDMINER-Prozess kann aus Operatoren/Bausteinen zusammenglickt und konfiguriert werden. Diese Bausteine bilden alle gängigen Aufgaben der Datenanalyse ab und sind über verschiedene Ports miteinander verknüpfbar. KNIME ist ebenfalls eine offene Analyseplattform für Datenpipelines. KNIME ermöglicht die Visualisierung und Manipulation von Daten durch die Erstellung von Data-Analytics-Workflows. Es ermöglicht die Manipulation von Datenquellen aus verschiedenen Quellen wie Dateien, Datenbanken, Azure, Twitter oder Google Sheets u. v. m. Außerdem ermöglicht es die Erstellung von Statistiken, die Aggregation und Bereinigung von Daten. Darüber hinaus ist eine Datenvisualisierung, Anwendung von Algorithmen des maschinellen Lernens und Erstellung von Modellen für verschiedene Zwecke (Klassifizierung, Regression, Clustering) möglich sowie die Validierung der Modelle und die gemeinsame Nutzung von Erkenntnissen.

Separat seien auch noch die Auto-ML-Tools zu erwähnen, welche gerade für Analytics- und ML-Anfänger eine gute Unterstützung bieten können, da sie Einstiegsbarrieren in den ML-Bereich beseitigen und so eine schnelle Umsetzung von Use Cases ermöglichen. Beispiele für Open-Source-Tools sind AUTOKERAS, AUTO-SKLEARN und TPOT. Auch Cloud Services von Google, Amazon und Microsoft wie GOOGLE AUTOML und AMAZON SAGEMAKER werden immer beliebter, da sie gleichzeitig Rechenkapazität zur Verfügung stellen.

Auto-ML kann aktuell vor allem bei den folgenden Aufgaben eingesetzt werden:

- **Hyperparameteroptimierung:** Hyperparameter-Optimierung zielt darauf ab, eine gut funktionierende Hyperparameterkonfiguration eines gegebenen maschinellen Lernmodells auf einem vorliegenden Datensatz zu finden, einschließlich

des maschinellen Lernmodells, seiner Hyperparameter und anderer Datenverarbeitungsschritte.

- **Architektursuche:** Insbesondere bei neuronalen Netzen kann die Suche nach einer optimalen Architektur automatisiert unterstützt werden. Neural Architecture Search (NAS) automatisiert den Prozess des Architekturentwurfs neuronaler Netze. NAS-Ansätze optimieren die Topologie der Netze, einschließlich der Art und Weise, wie Knoten zu verbinden sind und welche Operatoren zu wählen sind.
- **Kombinierte Modellauswahl:** Auto-ML bietet gute Unterstützung dabei das am besten auf den Daten performende Modell zu finden.
- **Feature Engineering:** Automatisches Extrahieren von Merkmalen und – aus einer großen Anzahl von Merkmalen – Identifizierung derjenigen mit hoher Vorhersagekraft.

Mithilfe der Kriterien aus Abschnitt 3.3.2 können auch diese Tools für die Modellierung ausgewählt werden. Es kann sinnvoll sein, das Kern-Framework für die Modellierung vor den Tools für die Vorverarbeitung zu wählen, um es dann mit kompatiblen, spezielleren Bibliotheken zu kombinieren (vgl. Abschnitt 3.3.2).

Die ausgewählten Tools unterstützen schließlich dabei die entsprechenden Techniken erfolgreich zu implementieren.

3.3.4 Modell-Evaluation

Die Evaluation ist für jeden Data-Analytics-Prozess von zentraler Bedeutung. Sie dient den folgenden Zwecken [Ras18]:

- **Performance-Messung:** Dies dient dazu zu prüfen, wie gut das Modell generalisiert, also unbekannte Daten vorhersagt.
- **Modell-Selektion:** Hier ist das Ziel die Optimierung einer Performance-Metrik. Dazu wird nach dem besten Modell aus einer Reihe von Modellen gesucht, die mit verschiedenen Hyperparametereinstellungen erstellt wurden.
- **Modell- und Algorithmen-Vergleich:** Zweck ist die Auswahl des Algorithmus, der für das vorliegende Problem am besten geeignet ist. Dazu werden Algorithmen-Alternativen verglichen.

Die Modelle bzw. die gesamten Pipelines werden also in der letzten Phase des Hauptprozesses hinsichtlich des technischen Erfolges bewertet. Damit ein zufriedenstellendes Ergebnis erreicht wird, müssen die vorhergehenden Schritte ggf. oft wiederholt werden. Der Analytics-Prozess ist immer iterativ. Wie bereits in Abschnitt 3.3.3 erwähnt, können Auto-ML-Ansätze hier unterstützen, um schnell das am besten performende Modell zu finden.

Bei der Evaluation wird zudem die Unterscheidung zwischen überwachten und unüberwachten Methoden relevant. Wenn Labels vorhanden sind, wie es das überwachte Lernen erfordert, ist es oft viel einfacher die Modell-Performance zu bewerten, da die korrekten

Outputs bekannt sind. Hier ist vor allem zu beachten, dass das Modell nicht auf dem gesamten Datensatz trainiert wird. Typischerweise wird ein Train/Test-Split gemacht mit 70 % Trainingsdaten und 30 % Testdaten. Neue Daten für die Evaluation zu verwenden ist sehr wichtig, um die Wahrscheinlichkeit des Overfittings zu reduzieren, d. h. eine Überanpassung des Modells an den gegebenen Datensatz. Um zu überprüfen, ob das Modell auf Datenstichproben, für die es nicht trainiert wurde, gut performt, können Resampling-Methoden angewendet werden. Das sind Techniken zur Neuordnung von Datenstichproben. Neben dem zufälligen Train/Test-Split ist noch die k -faltige Kreuzvalidierung sehr beliebt, die den Datensatz zufällig mischt und es anschließend in k Gruppen (= Faltung) aufteilt. Eine Faltung an Daten wird zum Testen des Modells verwendet und die Restlichen zum Trainieren. Der ganze Prozess wird mit einer anderen Faltung zum Testen wiederholt, bis alle Faltungen zum Testen verwendet wurden. Am Ende ist jeder Block einmal für die Testdaten zuständig gewesen. Aus allen Testungen wird ein Durchschnitt berechnet. Damit wird das Risiko reduziert, zufällig nicht-repräsentative Testdaten auszuwählen. Durch das Wiederholen wird das Ergebnis robuster, da die Varianz sinkt.

Bei der Klassifikation können vier Typen von Ergebnissen auftreten:

- **Richtig positiv (TP):** Wenn vorhergesagt wird, dass eine Beobachtung zu einer Klasse gehört, und sie tatsächlich zu dieser Klasse gehört.
- **Falsch negativ (FN):** Wenn vorhergesagt wird, dass eine Beobachtung nicht zu einer Klasse gehört, obwohl sie in Wirklichkeit dazu gehört.
- **Falsch positiv (FP):** Wenn vorhergesagt wird, dass eine Beobachtung zu einer Klasse gehört, obwohl sie in Wirklichkeit nicht dazu gehört.
- **Richtig negativ (TN):** Wenn vorhergesagt wird, dass eine Beobachtung nicht zu einer Klasse gehört, und sie tatsächlich nicht zu dieser Klasse gehört.

Vor allem drei Metriken werden genutzt, um ein Klassifikationsmodell auf den Testdaten zu evaluieren:

- **Genauigkeit:** Anteil an richtigen Vorhersagen.
- **Präzision:** Anteil an richtig vorhergesagten positiven Ergebnissen (TP), bezogen auf die Gesamtheit aller als positiv vorhergesagten Ergebnisse.
- **Recall:** Anteil der korrekt als positiv klassifizierten Ergebnisse (TP), bezogen auf die Gesamtheit der tatsächlich positiven Ergebnisse.

Beim unüberwachten Lernen ist es häufig so, dass das Modell nur der erste Schritt eines längeren Analytics-Workflows war und die Nützlichkeit des Ergebnisses durch den Erfolg der größeren Operation wie ein Vorhersagemodell geprüft werden kann. Wenn das unüberwachte Modell für sich der Erkenntnisgewinnung dient und der Output menscheninterpretierbar sein sollte, können entweder auch hier externe Daten zur Einschätzung helfen oder intrinsische Validierungsverfahren. Letztere stehen z. B. beim Clustering zur Verfügung und basieren auf den durch die Daten zur Verfügung stehenden Informationen.

Der Analytics-Baukasten (vgl. Abschnitt 3.3.2; Bild 3-25) zeigt die Metriken auf, die in der Betriebsdaten-gestützten Produktplanung häufig genutzt werden.

Die Auswahl der richtigen Metriken für das betrachtete Modell ist sehr wichtig, da das Modell anhand einer Metrik zufriedenstellende Ergebnisse liefern kann, mit einer anderen Metrik jedoch schlechte. Zur Unterstützung der Auswahl der richtigen Evaluationsmethoden für Data-Mining-Modelle bieten z. B. SOUZA ET AL. Muster an [SMJ02]. Diese unterstützen dabei zu entscheiden, welche Form der Evaluierung bei der eigenen Datenlage etc. angewendet werden sollte.

Nachdem die implementierten Modelle mit den passenden Metriken evaluiert wurden, können die Ergebnisse des am besten performenden Modells an den nächsten Hauptprozess übergeben werden.

3.4 Verwertung von Betriebsdaten-Analysen

Im vierten Hauptprozess des Referenzprozesses für die Betriebsdaten-gestützte Produktplanung wird die Verwertung von Betriebsdaten-Analysen fokussiert. Gegenstand dieses Prozesses ist die umfassende und systematische Nutzung der Analyse-Ergebnisse in der strategischen Produktplanung. Das Vorgehen besteht aus vier Phasen:

- (1) In der **Ergebnis-Interpretation** werden die Ergebnisse der Betriebsdaten-Analyse systematisch beurteilt und in Verbesserungspotentiale für neue Produktgenerationen überführt.
- (2) Im Rahmen der **Zielsystem-Überarbeitung** wird das Zielsystem der geplanten Produktgeneration vor dem Hintergrund der Betriebsdaten-Analyse überarbeitet.
- (3) Gegenstand der **Ideenfindung** ist die Suche und Auswahl Erfolg versprechender Ideen zur Erfüllung der definierten Ziele.
- (4) Die **Umsetzungsplanung** dient der Überarbeitung der Produktstrategie, mit der die verfolgte Produktvision realisiert werden soll.

Das methodische Vorgehen ist in Bild 3-27 dargestellt und wird nachfolgend beschrieben.

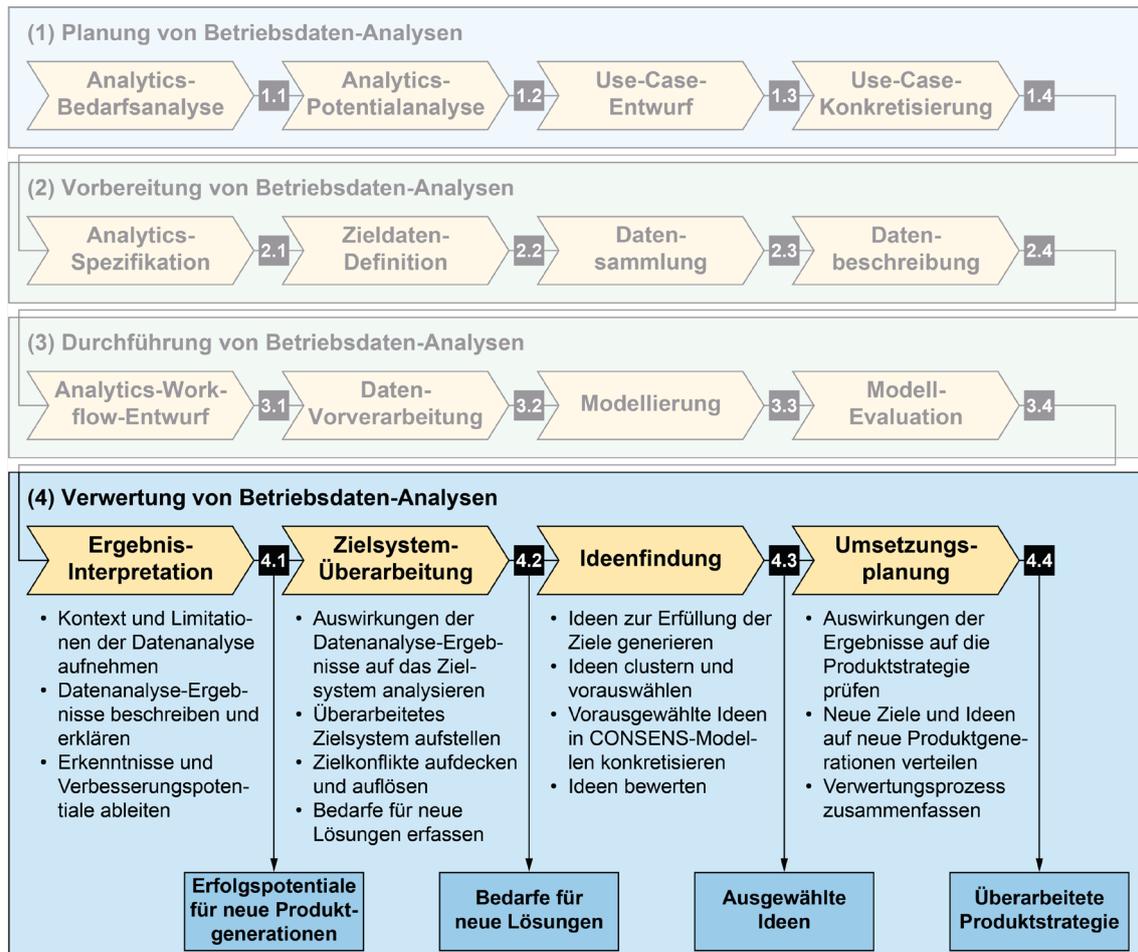


Bild 3-27: Vorgehen für die Verwertung von Betriebsdaten-Analysen in der strategischen Produktplanung

3.4.1 Ergebnis-Interpretation

In der ersten Phase des Hauptprozesses „Verwertung von Betriebsdaten-Analysen“ steht die Interpretation der Datenanalyse-Ergebnisse im Fokus. Hier geht es darum, Erkenntnisse aus den Datenanalyse-Ergebnissen herauszuarbeiten und Verbesserungspotentiale für zukünftige Produktgenerationen aufzudecken. Charakterisiert wird dies durch die Leitfrage: *Was bedeuten die Ergebnisse der Betriebsdaten-Analyse für neue Produktgenerationen?*

Die systematische Interpretation von Datenanalyse-Ergebnissen setzt sich aus drei aufeinanderfolgenden Schritten zusammen: Zunächst werden der Kontext und die Limitationen von Datenerhebung und -analyse festgehalten. Dann werden die Datenanalyse-Ergebnisse beschrieben und bewertet. Abschließend erfolgt die Ableitung von Erkenntnissen und die Identifizierung von Verbesserungspotentialen für neue Produktgenerationen. Diese Schritte gehen auf die Prinzipien zur Verwertung von Datenanalyse-Ergebnissen nach MEYER ET AL. zurück [MFK+22b].

Das Festhalten des Kontexts und der Limitationen von Datenerhebung und -analyse stellt eine wichtige Voraussetzung für die richtige Interpretation der Ergebnisse der Datenanalyse dar. Werden Kontext und Limitationen nicht beachtet, sind Fehlinterpretationen der Ergebnisse wahrscheinlich. Deshalb wird in diesem Schritt genau beschrieben, in welchem Kontext die Datenerhebung stattfand (z. B. über einen Zeitraum von drei Wochen im Sommer) und welchen Limitationen sie unterlag (z. B. keine Daten außerhalb der Ferien- und Urlaubszeit). Im Anschluss werden das Vorgehen zur Datenanalyse beschrieben und die daraus resultierenden Limitationen aufgenommen. Darauf aufbauend wird abschließend beantwortet, wie gut sich die aufgenommenen Daten und das gewählte Vorgehen zur Datenanalyse für die Beantwortung der Fragestellungen eignen.

Sind der Kontext und die Limitationen der Betriebsdaten-Analyse geklärt, folgen die Beschreibung und Bewertung der Datenanalyse-Ergebnisse. Hier wird zunächst beschrieben, was die Ergebnisse zeigen und was dabei auffällt (z. B. regelmäßige Änderungen der Einstellungen). Anschließend wird von Produkt- und Analytics-Experten gemeinsam erörtert, was die Ergebnisse tatsächlich aussagen – und was nicht (z. B., dass Nutzer regelmäßig Einstellungen ändern, aber nicht, warum sie dies tun). Sobald diese Aussagen stehen, wird bewertet, wie plausibel und sicher der identifizierte Zusammenhang ist. Dabei geht es um eine Einschätzung, inwieweit die Ergebnisse von den Parametern der Datenerhebung und -analyse beeinflusst wurden und inwiefern sie sich verallgemeinern lassen. Abschließend wird außerdem diskutiert, welche Biases (Wahrnehmungsverzerrungen) die Bewertung der Datenanalyse-Ergebnisse wie stark beeinflussen.

Nach der umfassenden Beschreibung und Bewertung der Ergebnisse der Datenanalyse steht die Erarbeitung von Erkenntnissen und Verbesserungspotentialen im Fokus. Erkenntnisse stellen dabei die Erweiterung des bisherigen Wissensstands dar. Es wird daher zuerst geprüft, welches neue Wissen die Datenanalyse-Ergebnisse in sich tragen (z. B. neue Verhaltensmuster der Nutzer). Vor diesem Hintergrund werden anschließend Schlussfolgerungen und Implikationen herausgearbeitet (z. B. das Produkt kann die Wünsche der Nutzer nicht mehr vollständig erfüllen). Diese werden mit Informationen und Wissen aus anderen Quellen abgesichert (z. B. persönliche Erfahrungen der Experten oder Ergebnisse einer Kundenumfrage). In einer finalen Diskussion werden abschließend die spezifischen Verbesserungspotentiale für die Planung neuer Produktgenerationen ermittelt (z. B. mehr individuelle Konfigurationsmöglichkeiten). Die Erkenntnisse, Schlussfolgerungen, Implikationen und Verbesserungspotentiale stellen Eingangsgrößen für die nachfolgende Phase dar.

Die Interpretation der Datenanalyse-Ergebnisse findet am besten in einem Workshop mit einem heterogenen Team statt. Gerade in dieser Phase ist es essentiell, möglichst viele unterschiedliche Perspektiven zusammenzubringen. Dies kann sich zum Beispiel auf den fachlichen Hintergrund, die Abteilung oder die Hierarchieebene beziehen. Auch die Einbindung von Externen kann sehr hilfreiche Impulse liefern. Um die Interpretation mit zahlreichen Personen zu unterstützen, wird die Interpretation der Datenanalyse-Ergeb-

nisse mit einem Interpretations-Canvas durchgeführt. Dieses stellt die drei Schritte in einzelnen Bereichen dar und präsentiert Leitfragen, mit denen eine umfassende Interpretation und Diskussion der Datenanalyse-Ergebnisse gewährleistet wird. Das Interpretations-Canvas ist in Bild 3-28 dargestellt.

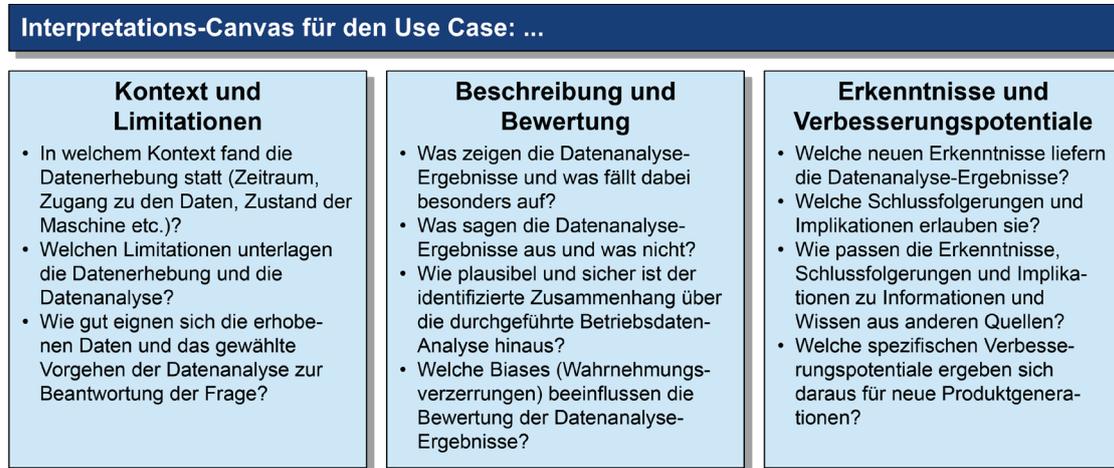


Bild 3-28: Interpretations-Canvas mit Leitfragen

3.4.2 Zielsystem-Überarbeitung

Die zweite Phase des Hauptprozesses „Verwertung von Betriebsdaten-Analysen“ umfasst die Zielsystem-Überarbeitung. In dieser Phase werden die Auswirkungen der Erkenntnisse, Schlussfolgerungen, Implikationen und Verbesserungspotentiale auf das ursprüngliche Zielsystem geprüft. Dieses wird entsprechend überarbeitet. Die Leitfrage lautet: *Wie müssen wir unser ursprüngliches Zielsystem vor dem Hintergrund der Ergebnisse der Betriebsdaten-Analyse überarbeiten?*

Zunächst werden die Erkenntnisse, Schlussfolgerungen und Implikationen der Betriebsdaten-Analyse sowie die aus ihnen identifizierten Verbesserungspotentiale dem ursprünglichen Zielsystem der neuen Produktgenerationen gegenübergestellt. Das Zielsystem kann dabei neben der Produktvision in Form des Produktprofils auch weitere Elemente umfassen, die für die Planung der neuen Produktgeneration relevant sind. So können zum Beispiel auch Anforderungen, Anwendungsfälle und Funktionen im Zielsystem der Produktvision beschrieben werden, um ihre Konsistenz mit der Betriebsdaten-Analyse zu prüfen. Für jedes Element des Zielsystems wird analysiert, welche Auswirkungen die Erkenntnisse der Betriebsdaten-Analyse, die Schlussfolgerungen und Implikationen sowie die Verbesserungspotentiale auf das jeweilige Element haben. Dabei können zum Beispiel Widersprüche zwischen den Erkenntnissen der Betriebsdaten-Analyse und Zielsystem-Elementen aufgedeckt werden. Systematisch kann diese Gegenüberstellung mit Hilfe einer Matrix durchgeführt werden, in der die Zielsystem-Elemente in den Zeilen und die Erkenntnisse und Schlussfolgerungen der Betriebsdaten-Analyse in den Spalten aufgeführt sind. In den jeweiligen Schnittpunkten wird dann paarweise bewertet, ob und welche

Auswirkungen die Betriebsdaten-Analyse auf die Zielsystem-Elemente hat. Die identifizierten Auswirkungen sind detailliert festzuhalten.

Im Anschluss an die Auswirkungsanalyse wird das Zielsystem überarbeitet, d. h. das Produktprofil und weitere Zielsystem-Elemente werden vor dem Hintergrund der Betriebsdaten-Analyse aktualisiert. Dabei sind folgende Operationen möglich: (1) Zielsystem-Elemente werden aus dem ursprünglichen Zielsystem in das überarbeitete Zielsystem übernommen; (2) Zielsystem-Elemente werden in veränderter Form aus dem ursprünglichen Zielsystem in das überarbeitete Zielsystem übertragen; (3) Neue Zielsystem-Elemente, die aus den Erkenntnissen der Betriebsdaten-Analyse und den Verbesserungspotentialen folgen, werden im überarbeiteten Zielsystem ergänzt; (4) Zielsystem-Elemente werden aus dem ursprünglichen Zielsystem nicht in das überarbeitete Zielsystem übernommen, sondern entfernt [Meb08]. Bild 3-29 stellt diese Zusammenhänge dar.

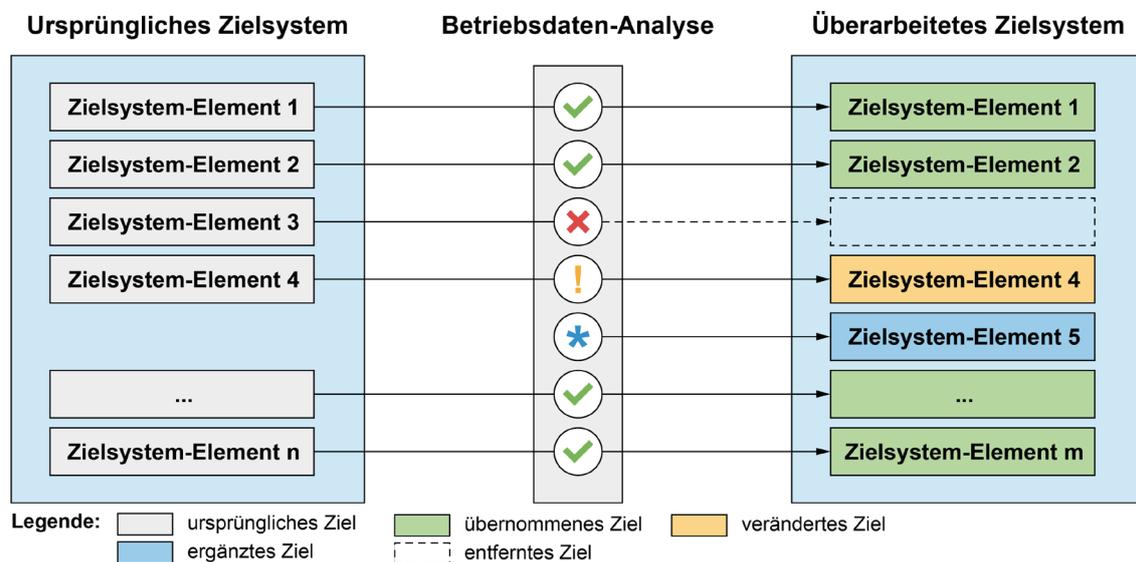


Bild 3-29: Überarbeitung des Zielsystems mit Betriebsdaten-Analysen

Ist das überarbeitete Zielsystem initial aufgestellt, ist es auf Zielkonflikte zu prüfen. Ein Zielkonflikt beschreibt die Inkonsistenz von zwei oder mehr Zielen, d. h. sie sind nicht miteinander vereinbar. Zur Analyse von Zielkonflikten kann zum Beispiel eine Korrelationsmatrix mit den Zielsystem-Elementen aufgebaut werden [PL11]. In dieser werden die Beziehungen der Zielsystem-Elemente paarweise überprüft. Existieren Konflikte, werden diese durch Veränderungen von Zielsystem-Elementen aufgelöst.

Sobald alle Inkonsistenzen aus dem Zielsystem aufgelöst sind, werden die vorgenommenen Veränderungen am Zielsystem zusammengefasst. Dies kann im einfachsten Fall mit einer Liste geschehen. Eine solche Liste umfasst dann alle Punkte, die in Folge der Betriebsdaten-Analyse neue Lösungen für die geplanten neuen Produktgenerationen erfordern. Diese bilden den Ausgangspunkt für die sich anschließende Phase der Ideenfindung.

3.4.3 Ideenfindung

Die Ideenfindung repräsentiert die dritte Phase des Hauptprozesses „Verwertung von Betriebsdaten-Analysen“. Hier werden neue Ideen zur Erschließung der identifizierten Verbesserungspotentiale und Erfüllung der definierten Ziele für neue Produktgenerationen gesucht und ausgewählt. Dies geht einher mit der Leitfrage: *Mit welchen Ideen können wir die identifizierten Verbesserungspotentiale für neue Produktgenerationen erschließen?*

Nach den eher analytischen Phasen der Ergebnis-Interpretation und Zielsystem-Überarbeitung wird in der Phase der Ideenfindung die Kreativität in den Vordergrund gestellt. Das Vorgehen orientiert sich an den vier letzten Phasen des Vorgehens bei Ideation Events nach GAUSEMEIER ET AL.: Ideengenerierung, Clustering, Erprobung und Auswahl [GDE+19].

Zunächst steht die Generierung von Ideen im Fokus. Da die kreative Leistung im Laufe des Berufslebens abnimmt, ist eine Erhöhung der Kreativität durch die gezielte Anwendung von Kreativitätstechniken notwendig [GDE+19]. Dabei gibt es nicht die eine richtige Kreativitätstechnik. Vielmehr eignen sich die unterschiedlichen Kreativitätstechniken in unterschiedlichen Situationen, da sie unterschiedliche Ansätze verfolgen und zum Beispiel eher das intuitive oder das diskursive Denken fördern [FG13], [EM13]. Bild 3-30 zeigt einige bewährte Kreativitätstechniken, die eher das intuitive Denken, das diskursive Denken oder beides ausgeglichen unterstützen. Weitere Informationen zu diesen Kreativitätstechniken sind in [GDE+19] zu finden.

Unabhängig davon, welche Kreativitätstechnik gewählt wird, liegt der Schwerpunkt in diesem Schritt auf der Generierung vieler und vielfältiger Ideen. Je nachdem, wie viele Ideen dabei entwickelt werden, sollte im Anschluss ein Clustering und eine erste Vorauswahl durchgeführt werden [GDE+19]. Auf diese Weise werden ähnliche Ideen kombiniert, unrealistische Ideen eliminiert und die Gesamtmenge an Ideen auf die Wesentlichen reduziert. Für die Vorauswahl eignen sich wieder pragmatische Methoden wie das Punktleben.

Die verbleibende Auswahl an Ideen wird im Anschluss modelliert, um sie zu konkretisieren, ein gemeinsames Verständnis aufzubauen und ihre Beurteilbarkeit zu unterstützen. So gibt zum Beispiel die Darstellung einer Idee in einem CONSENS-Wirkstrukturmodell des betrachteten Produkts erste Hinweise darauf, wie groß der Änderungsaufwand bei einer Entscheidung für diese Idee wäre.

Intuitives Denken	Ausgeglichen intuitiv-diskursives Denken	Diskursives Denken
Brainstorming	Laterales Denken	Morphologischer Kasten
Brainwriting	Design Thinking	Analyse bekannter technischer Systeme
Methode 365	Delphi-Methode	Bionik
Analogiebildung	TRIZ	Konstruktionskataloge

Bild 3-30: Auswahl an Kreativitätstechniken für die Unterstützung des intuitiven, des diskursiven und des ausgeglichen intuitiv-diskursiven Denkens

Nach der Modellierung folgt die systematische Bewertung der vorausgewählten Ideen. Dafür wird eine Nutzwertanalyse durchgeführt. Diese stellt ein strukturiertes Vorgehen zur Findung der bestmöglichen Lösung aus einer Reihe an Alternativen dar, wenn vielfältige Aspekte zu berücksichtigen und mehrere Personen am Entscheidungsprozess beteiligt sind [Küh19]. Mit den vorausgewählten Ideen stehen die Entscheidungsalternativen bereits fest. Für die Nutzwertanalyse sind noch mehrere Bewertungskriterien auszuwählen und zu gewichten. Exemplarische Bewertungskriterien sind der Änderungsaufwand und das Geschäftspotential. Für die Gewichtung gibt es mehrere Methoden, die in [Küh19] vorgestellt werden. Stehen Entscheidungsalternativen und Bewertungskriterien fest, werden diese in einer Matrix gegenübergestellt. Anschließend wird jede Entscheidungsalternative anhand jedes Bewertungskriteriums bewertet und die Gesamtpunktzahl je Alternative ermittelt. Eine exemplarische Nutzwertanalyse am Beispiel der Kaffeemaschine ist in Bild 3-31 dargestellt.

Bewertungskriterien	Gew.	Leistungsstärkere Brüheinheit		Touch-Display		Größere Tropfschale	
		Bewertung	Punktwert	Bewertung	Punktwert	Bewertung	Punktwert
Innovationsgrad	0,15	2	0,3	9	1,35	1	0,15
Usability	0,35	4	1,4	6	2,1	6	2,1
Kosten	0,2	5	1	3	0,6	10	2
Aufwand	0,3	9	2,7	1	0,3	7	2,1
Summe	100		5,4		4,35		6,35

Bild 3-31: Nutzwertanalyse von Ideen am Beispiel einer Kaffeemaschine

Die bewerteten Ideen werden daraufhin in einem Steckbrief aufbereitet. Dieser bündelt die verfügbaren Informationen und dient damit als Entscheidungsgrundlage für die Auswahl an Ideen, die in der Umsetzungsplanung weiterbetrachtet werden sollen. Da das Ergebnis der Nutzwertanalyse darauf einen bedeutenden Einfluss hat, ist diese auf dem Steckbrief aufgeführt, ebenso wie eine Beschreibung der Idee und ein erstes technisches Konzept. Bild 3-32 stellt einen exemplarisch ausgefüllten Ideensteckbrief dar.

Idee für neue Produktgenerationen: Touch-Display

Beschreibung

Aus der Betriebsdaten-Analyse geht hervor, dass Nutzer immer wieder Probleme mit der Bedienung der Kaffeemaschine haben. Dies äußert sich zum Beispiel in zahlreichen Tasten-Betätigungen in Situationen, in denen diese aufgrund laufender Hintergrundprozesse gar nicht verarbeitet werden können. Um die Bedienung der Kaffeemaschine intuitiver zu machen, soll daher ein neues Touch-Display die zukünftige Schnittstelle zu den Nutzern darstellen.

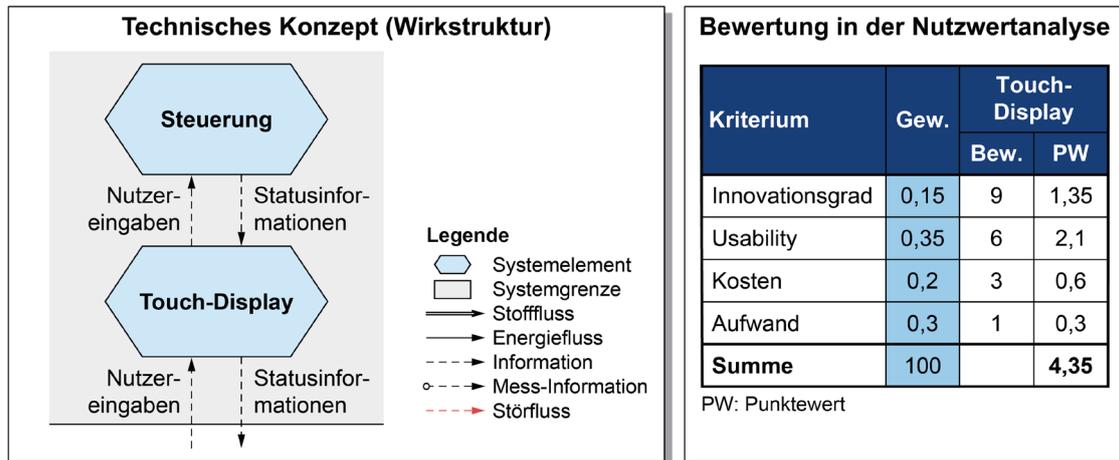


Bild 3-32: Exemplarisch ausgefüllter Ideensteckbrief

3.4.4 Umsetzungsplanung

Gegenstand der vierten Phase des Hauptprozesses „Verwertung von Betriebsdaten-Analysen“ ist die Umsetzungsplanung. In dieser werden die in den vorherigen Phasen erarbeiteten Ergebnisse in die Produktstrategie integriert. Die zugehörige Leitfrage lautet entsprechend: *Wie sollten wir unsere Produktstrategie vor dem Hintergrund der Betriebsdaten-Analyse und der daraus abgeleiteten Erkenntnisse und Ergebnisse überarbeiten?*

Zunächst wird in dieser Phase geprüft, welche Auswirkungen die Erkenntnisse der Betriebsdaten-Analyse, die identifizierten Verbesserungspotentiale, das überarbeitete Zielsystem und die ausgewählten Ideen auf die Produktstrategie haben. Nach GAUSEMEIER ET AL. beschreibt eine Produktstrategie im Wesentlichen drei Handlungsfelder [GDE+19]:

- (1) Die **Differenzierung im Wettbewerb** bündelt Fragen zur Positionierung des Produkts im Markt. Dabei werden zum Beispiel Differenzierungsmerkmale und notwendige Produktvarianten ermittelt.
- (2) Die **Bewältigung der Variantenvielfalt** behandelt die profitable Gestaltung der notwendigen Produktvarianten. Dafür sind geeignete Maßnahmen zu definieren.
- (3) Der Schwerpunkt der **Erhaltung des Wettbewerbsvorsprungs** ist die Produkt-evolution. Hier muss festgelegt werden, wie sich das Produkt im Laufe der Zeit weiterentwickeln soll, um auch langfristig erfolgreich zu sein.

Besteht eine derartige Produktstrategie noch nicht, werden von GAUSEMEIER ET AL. zahlreiche Methoden zur Ausgestaltung aller drei Handlungsfelder gezeigt [GDE+19]. Vorausgesetzt, dass eine solche Produktstrategie besteht, werden die Erkenntnisse der Betriebsdaten-Analyse, die identifizierten Verbesserungspotentiale, das überarbeitete Zielsystem und die ausgewählten Ideen den drei Handlungsfeldern nacheinander gegenübergestellt. Dabei wird geprüft, welche Änderungen durch die Betriebsdaten-Analyse und die daraus abgeleiteten Konsequenzen und Maßnahmen notwendig werden. Zum Beispiel können ein identifiziertes Verbesserungspotential und eine dazugehörige Idee eine neue Möglichkeit zur Differenzierung im Wettbewerb eröffnen, für die eine neue Produktvariante entwickelt werden soll. Die Überarbeitung der Produktstrategie wird in Bild 3-33 konzeptionell dargestellt.

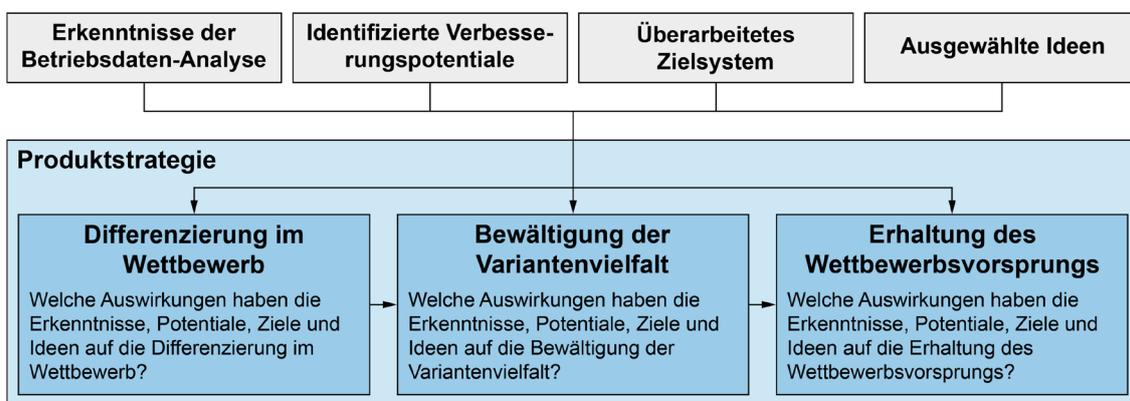


Bild 3-33: Überarbeitung der Produktstrategie

Wenngleich alle Handlungsfelder der Produktstrategie eine ähnliche Relevanz besitzen, werden im Folgenden die Auswirkungen der Betriebsdaten-Analyse auf das Handlungsfeld *Erhaltung des Wettbewerbsvorsprungs* fokussiert. Denn dort werden die in Folge der Betriebsdaten-Analyse identifizierten neuen Ziele und Ideen den bereits geplanten Produktgenerationen zugewiesen. Dabei ist sicherzustellen, dass alle Generationen eine ausreichende Nutzensteigerung versprechen, mit der insbesondere Kunden begeistert und zum Kauf motiviert werden. Außerdem wird auch darauf geachtet, dass sich das Entwicklungsrisiko einer jeden Produktgeneration in einem vertretbaren Rahmen bewegt. Die Kombinationen aus Zielen und Risiken sind demnach so auf die geplanten Produktgenerationen zu verteilen, dass jede Generation ein ausreichendes Begeisterungspotential besitzt und gleichzeitig nicht mit einem unverhältnismäßigen Entwicklungsrisiko einhergeht.

Methodisch wird die Verteilung der Ziel-Ideen-Kombinationen auf die geplanten Produktgenerationen mit einem Innovationsportfolio in Anlehnung an das von HEISMANN unterstützt [Hei10]. Bild 3-34 zeigt dies exemplarisch für die Produktgeneration G_{n+1} . Für jede geplante Produktgeneration wird ein derartiges Innovationsportfolio aufgebaut. Die bereits vor der Betriebsdaten-Analyse eingeplanten Ziel-Ideen-Kombinationen werden entsprechend ihres erwarteten Kunden-, Anbieter- und Anwendernutzens auf der ei-

nen und ihres erwarteten Entwicklungsrisikos auf der anderen Seite in die Portfolios einsortiert. Die Portfolios zeigen dann für jede geplante Produktgeneration auf einen Blick, wie viele Begeisterung erzeugende und wie viele Risiken bergende Ziel-Ideen-Kombinationen für die jeweiligen Generationen geplant sind. Unterschiedliche Farben der Ziel-Ideen-Kombinationen weisen darüber hinaus darauf hin, ob diese ohne oder mit Veränderungen von der Vorgänger-Generation übernommen werden oder sogar gänzlich neu sind. Die aus der Betriebsdaten-Analyse hervorgehenden Ziel-Ideen-Kombinationen werden den geplanten Produktgenerationen daraufhin so zugeordnet, dass jede ein in Summe ausgeglichenes Nutzen-Risiko-Verhältnis aufweist.

Der Kunden-, Anbieter- und Anwendernutzen einer Ziel-Ideen-Kombination wird im Idealfall von einem heterogenen Team beurteilt. Zur Bewertung des Entwicklungsrisikos stellen zum Beispiel ALBERS ET AL. eine Methode bereit, die das Risiko auf Basis (1) der Herkunft der Referenzsystem-Elemente und (2) des Neuentwicklungsanteils (Ausprägungs- und Prinzipvariationen) bestimmt [ARB+17]. Soll die Verteilung nicht nur auf Generations-, sondern bis auf Release-Ebene erfolgen, stellen GAUSEMEIER ET AL. sowie KÜHN eine geeignete Lösung vor [GDE+19], [Küh17].

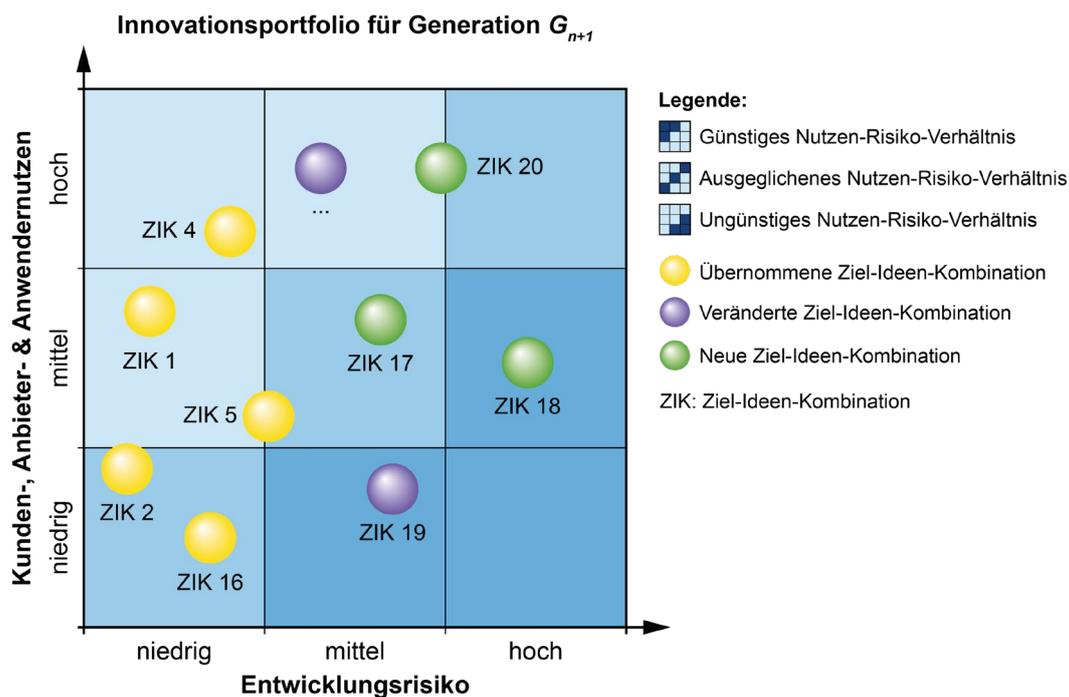


Bild 3-34: Exemplarisches Innovationsportfolio für die Produktgeneration G_{n+1} in Anlehnung an HEISMANN [Hei10]

Nach der Verteilung der Ziel-Ideen-Kombinationen auf die geplanten Produktgenerationen wird der Verwertungsprozess zusammengefasst, um transparent kommunizieren zu können, welche Auswirkungen die Betriebsdaten-Analysen auf die strategische Produktplanung hatten. Obwohl kein Teil der Verwertung, werden auch der Use Case und die Datenerhebung sowie -analyse kurz beschrieben. Damit wird festgehalten, warum die Betriebsdaten-Analyse überhaupt durchgeführt wurde, was konkret untersucht wurde und

- [AN55] AAMODT, A.; NYGARD, M.: Different Roles and Mutual Dependencies of Data, Information and Knowledge. In: *Data & Knowledge Engineering 1955*, S. 191–222
- [ARB+17] ALBERS, A.; RAPP, S.; BIRK, C.; BURSAC, N.: Die Frühe Phase der PGE – Produktgenerationsentwicklung. *Stuttgarter Symposium für Produktentwicklung*, 2017, S. 345–354
- [ASB16] ALMQUIST, E.; SENIOR, J.; BLOCH, N.: The Elements of Value. *Harvard Business Review*, 94, September, 2016, S. 46–53
- [Ber16] BERGER, W.: *A more beautiful question – The power of inquiry to spark break-through ideas*. 1. Auflage, Bloomsbury, New York, NY, 2016
- [CC00] CHAPMAN, P.; CLINTON, J.; KERBER, R.; KHABAZA, T.; REINARTZ, T.P.; SHEARER, C.; WIRTH, R.: *CRISP-DM 1.0: Step-by-step data mining guide*, 2000
- [EM13] EHRENSPIEL, K.; MEERKAMM, H.: *Integrierte Produktentwicklung – Denkabläufe, Methodeneinsatz, Zusammenarbeit*. 5. Auflage, Hanser, München, 2013
- [FG13] FELDHUSEN, J.; GROTE, K.-H.: *Pahl/Beitz Konstruktionslehre – Methoden und Anwendung erfolgreicher Produktentwicklung*. 8. Auflage, Springer Vieweg, Berlin Heidelberg, 2013
- [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
- [GP14] GAUSEMEIER, J.; PLASS, C.: *Zukunftsorientierte Unternehmensgestaltung – Strategien, Geschäftsprozesse und IT-Systeme für die Produktion von morgen*. 2. Auflage, Hanser, München, 2014
- [Hei10] Heismann, R.: Die Erweiterung des Innovationsprozesses bei Porsche. In: ILI, S.: *Open Innovation umsetzen. Prozesse, Methoden, Systeme, Kultur*. 1. Auflage, Symposium-Publishing, Düsseldorf, 2010, S. 115–146
- [KJR+18] KÜHN, A.; JOPPEN, R.; REINHART, F.; RÖLTGEN, D.; VON ENZBERG, S.; DUMITRESCU, R.: Analytics canvas—a framework for the design and specification of data analytics projects. *Procedia CIRP*, 70, 2018, S. 162–167
- [KSB+10] KIETZ, J.; SERBAN, F.; BERNSTEIN, A.; FISCHER, S.: *Data mining workflow templates for intelligent discovery assistance and auto-experimentation*, 2010
- [Küh17] KÜHN, A.: *Systematik zur Release-Planung intelligenter technischer Systeme*. Fakultät für Maschinenbau, Universität Paderborn, HNI-Verlagsschriftenreihe, Band 370, Paderborn, 2017
- [Küh19] KÜHNAPFEL, J. B.: *Nutzwertanalysen in Marketing und Vertrieb*. 2. Auflage, Springer Fachmedien, Wiesbaden, 2019
- [Meb08] MEBOLDT, M.: *Mentale und formale Modellbildung in der Produktentstehung – als Beitrag zum integrierten Produktentstehungs-Modell (iPeM)*. Fakultät für Maschinenbau, Karlsruher Institut für Technologie, Universität Karlsruhe (TH), Karlsruhe, 2008
- [MFK+22a] 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 (e14), 2022
- [MFK+22b] MEYER, M.; FICHTLER, T.; KOLDEWEY, C.; DUMITRESCU, R.: How can Data Analytics Results be Exploited in the Early Phase of Product Development? *13 Design Principles for Data-Driven Product Planning*. *AMCIS 2022 Proceedings*, 9, 2022
- [MPK+22] MEYER, M.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: 17 Use Cases for Analyzing Use Phase Data in Product Planning of Manufacturing Companies. *Procedia CIRP*, 107, 2022, S. 1053–1058

- [MWK+21] MEYER, M.; WIEDERKEHR, I.; KOLDEWEY, C.; DUMITRESCU, R.: Understanding Usage Data-Driven Product Planning: A Systematic Literature Review. Proceedings of the International Conference on Engineering Design (ICED21). 16.-20. August 2021, Gothenburg, Sweden, Cambridge University Press, 2021, S. 3289–3298
- [MWK+22] MEYER, M.; WIEDERKEHR, I.; KOLDEWEY, C.; DUMITRESCU, R.: Planning the Analysis of Use Phase Data in Product Planning. Proceedings of the DESIGN Society, 2, 2022, S. 753–762
- [MWP+22] MEYER, M.; WIEDERKEHR, I.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: A Reference Process Model for Usage Data-Driven Product Planning. Proceedings of the 55th Hawaii International Conference on System Sciences (HICSS 2022). 4.-7. Januar 2022, Virtual Event / Maui, Hawaii, USA, 2022
- [OPB+14] OSTERWALDER, A.; PIGNEUR, Y.; BERNARDA, G.; SMITH, A.: Value proposition design – How to create products and services customers want. Wiley, Hoboken, NJ, 2014
- [PEM+22] PANZNER, M.; VON ENZBERG, S.; MEYER, M. & DUMITRESCU, R.: Characterization of Usage Data with the Help of Data Classifications. Journal of the Knowledge Economy. 1-22. 10.1007/s13132-022-01081-z, 2022
- [PJR+00] CHAPMAN, P.; CLINTON, J.; KERBER, R.; KHABAZA, T.; REINARTZ, T.; SHEARER, C.; WIRTH, R.: CRISP-DM 1.0: Step-by-step data mining guide, 2000
- [PM22] PANICK, D.; MARRÉ, M.: Konzept zur Sensornachrüstung, Messdaten als Basis zur Kollaboration im Produktionsnetzwerk. In: Zeitschrift für wirtschaftlichen Fabrikbetrieb, Walter de Gruyter Verlag, Berlin/Boston, Germany, 117(12), 2022, S. 896–901
- [PME+22] PANZNER, M.; MEYER, M.; VON ENZBERG, S.; 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
- [PL11] PONN, J.; LINDEMANN, U.: Konzeptentwicklung und Gestaltung technischer Produkte – Systematisch von Anforderungen zu Konzepten und Gestaltlösungen. 2. Auflage, Springer, Heidelberg, 2011
- [Py199] PYLE, D.: Data preparation for data mining. Morgan Kaufmann, San Francisco, USA, 1999
- [Ras18] RASCHKA, S.: “Model evaluation, model selection, and algorithm selection in machine learning.” arXiv preprint arXiv:1811.12808, 2018
- [Ric76] RICE, J. R.: The algorithm selection problem. In Advances in computers, Vol. 15, 1976, S. 65-118
- [RKD17] REINHART, F.; KÜHN, A.; DUMITRESCU, R.: Layer Model for the Development of Data Science Applications in Plants and Machines. In: Bodden, E.; Dressler, F.; Dumitrescu, R.; Gausemeier, J.; Meyer auf der Heide, F.; Scheytt, C.; Trächtler, A. (Eds.): Wissenschaftsforum Intelligente Technische Systeme (WinTeSys) 2017, Paderborn, 2017
- [SMJ02] SOUZA, J.; MATWIN, S.; JAPKOWICZ, N.: Evaluating data mining models: a pattern language. In Proceedings of the 9th Conference on Pattern Language of Programs, Illinois, USA, 2002, S. 1–23
- [SSE+14] STEENSTRUP, K.; SALLAM, R.; ERIKSEN, L.; JACOBSON, S.: Industrial Analytics Revolutionizes Big Data in the Digital Business. Gartner Research G00264728, 2014
- [Zha16] ZHANG, L. (2016), “Big Data analytics for fault detection and its application in maintenance”, Luleå University of Technology, 2016

4 Effiziente Umsetzung in Unternehmen

Ingrid Wiederkehr, Lukas Isenberg, Maurice Meyer

Die Operationalisierung des Referenzprozesses für die Betriebsdaten-gestützte Produktplanung stellt etablierte Unternehmen vor eine Herausforderung. Zur Unterstützung einer effizienten Umsetzung im Unternehmen werden in Abschnitt 4.1 und Abschnitt 4.2 die Rollen und Kompetenzen für die Betriebsdaten-gestützte Produktplanung beleuchtet. Ferner werden Möglichkeiten zur Einbindung dieser Rollen und Kompetenzen in bestehende Organisationsformen in Abschnitt 4.3 vorgestellt. Abschließend werden Maßnahmen zur Incentivierung der Kunden für die Datenbereitstellung in Abschnitt 4.4 aufgezeigt.

4.1 Rollen im Kontext der Betriebsdaten-gestützten Produktplanung

Der Referenzprozess für die Betriebsdaten-gestützte Produktplanung zeichnet sich durch eine enge Verzahnung unterschiedlicher Akteure aus. Zur effizienten Umsetzung des Referenzprozesses für die Betriebsdaten-gestützten Produktplanung ist es notwendig, die Aufgabenbereiche und Verantwortlichkeiten der unterschiedlichen Akteure zu definieren und voneinander abzugrenzen. Es konnten sieben generische Rollen unterschieden werden. Diese wurden im Rahmen eines interdisziplinären Workshops nach dem Vorgehen von EKMAN ET AL. identifiziert [ERT16]. Sie werden im Folgenden beschrieben:

- **Produktmanager:** Der Produktmanager verantwortet den Prozess der Planung neuer Produkte bzw. Produktgenerationen auf Basis von Betriebsdaten sowie die Verwertung der Betriebsdaten-Analysen. Insbesondere übergeordnete Ziele seiner Business Unit und des Unternehmens finden hierbei Berücksichtigung. Vor diesem Hintergrund wird der Produktmanager während der Vorbereitung und Durchführung der Betriebsdaten-Analyse informiert.
- **Datenarchitekt:** Der Datenarchitekt ist für die systematische Sammlung und Beschreibung der zu analysierenden Daten zuständig. Er sorgt dafür, dass alle involvierten Akteure Zugriff auf die Daten erhalten, und bereitet die Daten für eine zielgerichtete Analyse auf.
- **Datenanalyst:** Der Datenanalyst verantwortet die Analytics-Spezifikation der Use Cases. Er stellt die Schnittstelle zwischen der Planung der Betriebsdaten-Analyse durch den Produktmanager und der Vorbereitung der Betriebsdaten-Analyse her (vgl. Abschnitt 3.1 und Abschnitt 3.2). Ferner zählen die Aufgabengebiete der Datenvorbereitung, Modellierung und Modell-Evaluation zu seinen Tätigkeiten.
- **Entwickler:** Der Entwickler verantwortet die (technische) Entwicklung neuer Produkte bzw. Produktgenerationen. Er besitzt ein ausgeprägtes Produktverständnis. Im Rahmen der Betriebsdaten-gestützten Produktplanung nimmt der Entwickler eine beratende Funktion ein, da sein eigentlicher Schwerpunkt, die Produktentwicklung, auf der Produktplanung basiert.

- **Serviceexperte:** Der Serviceexperte erlangt durch seinen engen Kundenkontakt eine hohe Expertise im Hinblick auf die Produktnutzung. So kann der Serviceexperte insbesondere Kundenbedürfnisse und -probleme einschätzen. Vor diesem Hintergrund nimmt er eine beratende Funktion ein.
- **Kundenexperte:** Die zentrale kaufmännische Schnittstelle zum Kunden stellt der Kundenexperte dar. Er besitzt umfangreiche Kenntnisse zu Kundenbedürfnissen und liefert ergänzende Informationen aus Kunden-, Markt- und Wettbewerbsanalysen. Vor diesem Hintergrund fungiert der Kundenexperte in beratender Funktion.
- **Manager:** Der Manager unterstützt bei der Etablierung und Durchführung der Betriebsdaten-gestützten Produktplanung. Er trifft strategische Entscheidungen und überwacht insbesondere die Priorisierung von Verbesserungsideen sowie die Aktualisierung der Produktstrategie.

Die Kurzbeschreibungen der sieben generischen Rollen verdeutlichen die unterschiedlichen Tätigkeitsbereiche. Die Rollen müssen nun den Aufgaben im Referenzprozess zugeordnet werden, damit der Referenzprozess im Unternehmen gelebt werden kann. Dazu eignet sich die **RACI**-Methode. Die Methode ermöglicht die Zuordnung von Aufgabebereichen und Verantwortlichkeiten. RACI ist ein Akronym und setzt sich aus den englischen Begriffen *Responsible*, *Accountable*, *Consulted* und *Informed* zusammen [Wit20]. Bild 4-1 zeigt diese Zuordnung, wobei diese als Orientierung dient und in Abhängigkeit der Ausgangssituation angepasst werden kann – sowohl im Hinblick auf die betrachteten Rollen als auch im Hinblick auf die Verantwortlichkeiten.

Prozessschritte	Rollen						
	Produktmanager	Datenarchitekt	Datenanalyst	Entwickler	Serviceexperte	Kundenexperte	Manager (C-Level)
(1.1) Analytics-Bedarfsanalyse	R			C	C		I
(1.2) Analytics-Potentialanalyse	R	C	C		C		I
(1.3) Use-Case-Entwurf	R			C			A
(1.4) Use-Case-Konkretisierung	R	C	I	C	C	C	I
(2.1) Analytics-Spezifikation	A C	C	R	C			
(2.2) Zieldaten-Definition	I	C	R				
(2.3) Datensammlung	I	R	C				
(2.4) Datenbeschreibung	I	R	C				
(3.1) Analytics-Workflow-Entwurf	I	C	R				
(3.2) Daten-Vorverarbeitung	I	C	R				
(3.3) Modellierung	I	C	R				
(3.4) Modell-Evaluation	I	C	R				
(4.1) Ergebnis-Interpretation	R		C	C	C	C	I
(4.2) Zielsystem-Überarbeitung	R			C		C	I
(4.3) Ideenfindung	R			C		I	A
(4.4) Umsetzungsplanung	R			I		I	A

Legende: **R** Responsible **A** Accountable **C** Consulted **I** Informed

Bild 4-1: Definition von Verantwortlichkeiten im Referenzprozess für die Betriebsdaten-gestützten Produktplanung mit Hilfe der RACI-Matrix

Unter *Responsible* wird eine Rolle verstanden, die zur Durchführung einer Aufgabe verantwortlich ist [Wit20]. *Accountable* beschreibt eine Rolle, die zur Prüfung von Ergebnissen befähigt ist [Wit20]. Oftmals delegiert diese Rolle Aufgaben an weitere Akteure. Zur Vermeidung einer Verantwortungsdiffusion (mehr als eine Person ist verantwortlich) oder eines Verantwortungsvakuums (keine Person ist verantwortlich) werden die bereits beschriebenen Rollen lediglich einem Akteur zugeteilt; während die folgenden Rollen mehrfach vergeben werden können. *Consulted* beschreibt eine Rolle, die über Informationen, Kenntnisse oder Erfahrungen verfügt, die zur Umsetzung der Tätigkeiten eines Ergebnisses benötigt werden [Wit20]. Eine Rolle, die als *Informed* bezeichnet wird, beschreibt eine Person, mit der Informationen ausgetauscht werden sollen; hierbei wird zwischen Informationsrecht und -pflicht unterschieden [Wit20].

4.2 Kompetenzen für die Betriebsdaten-gestützte Produktplanung

Zur Besetzung der vorgestellten Rollen, müssen Mitarbeiter über ein entsprechendes Vorwissen und dazugehörige Fähigkeiten verfügen. Daher werden relevante Kompetenzprofile entlang des Referenzprozesses für die Betriebsdaten-gestützten Produktplanung identifiziert. Diese werden den in Abschnitt 4.1 vorgestellten Rollenprofilen zugeordnet. Abschließend wird der Kompetenzentwicklungsbedarf für Mitarbeiter in produzierenden Unternehmen beleuchtet.

Im Rahmen des ersten Hauptprozesses **Planung von Betriebsdaten-Analysen** (vgl. Abschnitt 3.1) werden insbesondere Kompetenzen zur Produkt- und Kundenanalyse benötigt. Dies ermöglicht eine detaillierte Analyse der Ausgangssituation. Anschließend bedarf es der systematischen Planung des Data-Analytics-Vorhabens. Dazu zählen insbesondere die Definition von Zielen und Rahmenbedingungen (z. B. Ressourcen, Fähigkeiten etc.) des Data-Analytics-Vorhabens oder die Beschreibung von konkreten Use Cases.

Für den zweiten Hauptprozess **Vorbereitung von Betriebsdaten-Analysen** (vgl. Abschnitt 3.2) ist zunächst die Übersetzung des definierten Ziels aus dem ersten Hauptprozess in ein technisches Data-Analytics-Ziel von hoher Bedeutung. Dies bildet anschließend die Basis zur Zieldaten-Definition sowie zur Daten-Sammlung und -Beschreibung.

Der dritte Hauptprozess **Durchführung von Betriebsdaten-Analysen** (vgl. Abschnitt 3.3) erfordert Kompetenzen zum Entwerfen eines Analytics-Workflows und zur Daten-Vorverarbeitung. Darüber hinaus sind Kenntnisse zur Modellierung und Modell-Evaluation notwendig.

Der letzte Hauptprozess **Verwertung der Betriebsdaten-Analysen** (vgl. Abschnitt 3.4) bedarf Kompetenzen zur Interpretation der Analyseergebnisse; hierbei ist die konkrete Ableitung und Bewertung von Produktverbesserungsideen relevant. Darüber hinaus ist es wichtig, diese bezüglich des Kundennutzens sowie der technischen Umsetzbarkeit bewerten zu können.

Zur Bestimmung der spezifischen Kompetenzausprägungen (Soll-Ausprägungen) für die generischen Rollen, wurden die Kompetenzen in mehreren Workshops von interdisziplinären Experten aus Forschung und Praxis bewertet. Dafür wurde eine Skala von 1 (= niedrige Ausprägung) bis 4 (= hohe Ausprägung) gewählt. Insbesondere die Rollenprofile Produktmanager, Datenarchitekt und Datenanalyst stellen zentrale Kompetenzträger im Rahmen der Betriebsdaten-gestützten Produktplanung dar. Der Produktmanager wurde als zentraler Kompetenzträger zur Planung der Datenanalyse und zur Interpretation der Datenanalyse-Ergebnisse bewertet. Der Datenarchitekt stellt den zentralen Kompetenzträger hinsichtlich der Datenerhebung dar, während der Datenanalyst insbesondere die Analytics-Modelle implementiert und validiert. Bild 4-2 zeigt exemplarisch das Rollenprofil und die erforderlichen Kompetenzen für die Rolle „Produktmanager“.

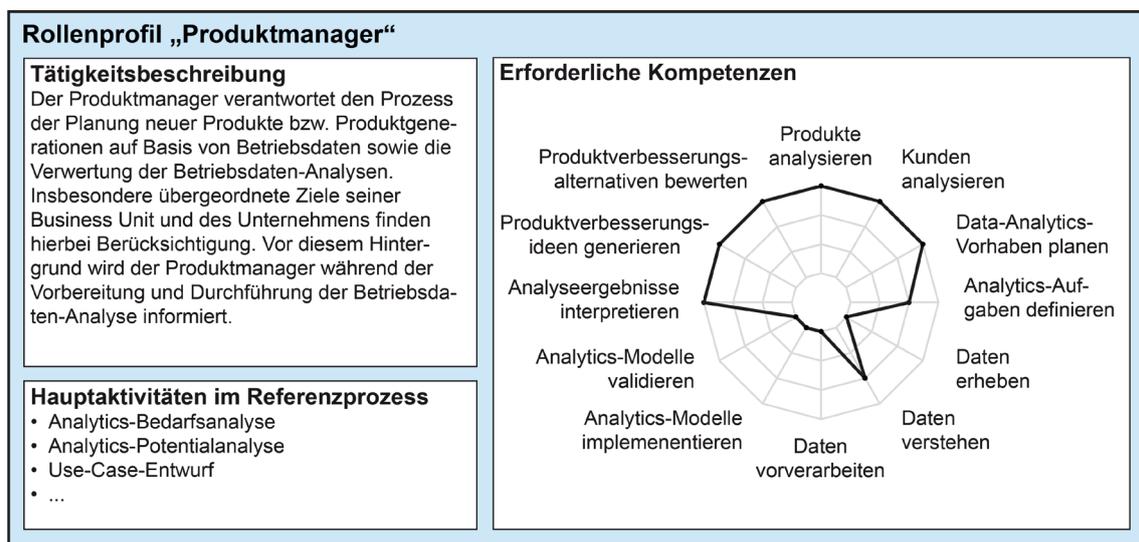


Bild 4-2: Rollenprofil und erforderliche Kompetenzen „Produktmanager“

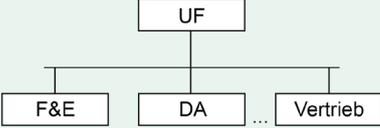
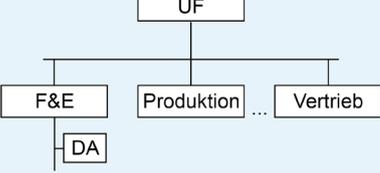
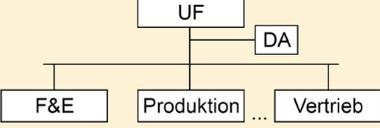
Zur effizienten Umsetzung der Betriebsdaten-gestützten Produktplanung in etablierten Unternehmen muss der Kompetenzentwicklungsbedarf für einzelne Mitarbeiter aufgenommen werden. Hierfür werden die generischen Rollenprofile (vgl. Abschnitt 4.1) mit den dazugehörigen Kompetenzprofilen bewertet. Dies ermöglicht einen Soll-Ist-Abgleich zwischen den benötigten Kompetenzen der Mitarbeiter. Es ergeben sich folgende Handlungsmöglichkeiten:

- **Keine Kompetenzentwicklungsmaßnahmen erforderlich:** Eine Besetzung der generischen Rollen ist mit bestehenden Mitarbeitern möglich, da das angestrebte Soll-Profil bereits erfüllt ist.
- **Geringe Kompetenzentwicklungsmaßnahmen erforderlich:** Eine Besetzung der generischen Rollen ist mit bestehenden Mitarbeitern möglich, wobei die Ist-Kompetenzausprägungen unterhalb der Soll-Ausprägungen liegen. Hierfür bieten sich bspw. Mitarbeiterschulungen an.
- **Gezielte Kompetenzentwicklungsmaßnahmen erforderlich:** Eine Besetzung der generischen Rollen ist nicht mit bestehenden Mitarbeitern möglich, da die

Soll- und Ist-Kompetenzprofile eine hohe Differenz aufzeigen. Hierfür werden Kooperationen mit Forschungseinrichtungen oder anderen Unternehmen empfohlen.

4.3 Organisatorische Verortung

Eine organisatorische Verortung der in Abschnitt 4.1 und Abschnitt 4.2 erläuterten Rollenprofile ist von der Ausgangssituation und Zielsetzung des betrachteten Unternehmens abhängig [GDE+19]. Beispielhaft genannt ist die etablierte Unternehmensstruktur oder das zur Verfügung stehende Budget. Folglich werden drei Empfehlungen zur organisatorischen Verortung von Data-Analytics-Ressourcen [SG16] vorgestellt; dabei werden die zentralen Vorteile der einzelnen Empfehlungen beleuchtet. Bild 4-3 zeigt die unterschiedlichen Empfehlungen zur organisatorischen Eingliederung von Data-Analytics-Ressourcen.

Eigenständige DA	Vor- und Nachteile
 <pre> graph TD UF[UF] --- F&E[F&E] UF --- DA[DA] UF --- Vertrieb[Vertrieb] </pre>	<ul style="list-style-type: none"> + Klare Führungsstrukturen + Strategische Funktion + Aufbau einheitlicher Analysestandards - Relativ hoher administrativer Aufwand/hohe Kosten - Erhöhter Koordinationsaufwand - Mögliche Zielkonflikte
Funktionale Eingliederung der DA	Vor- und Nachteile
 <pre> graph TD UF[UF] --- F&E[F&E] UF --- Produktion[Produktion] UF --- Vertrieb[Vertrieb] F&E --- DA[DA] </pre>	<ul style="list-style-type: none"> + Effiziente Koordination + Nutzung bestehender administrativer Strukturen + Aufbau spezifischen Wissens - Neigung zum „Silodenken“ - Anforderungen an Führungsfunktionen
DA als zentrale Stabstelle	Vor- und Nachteile
 <pre> graph TD UF[UF] --- F&E[F&E] UF --- Produktion[Produktion] UF --- Vertrieb[Vertrieb] UF --- DA[DA] </pre>	<ul style="list-style-type: none"> + Geringe Kosten + Sichtbarkeit auf Managementebene + Einheitliche Analysestandards - Fehlende Führungsstrukturen - Punktuelle Einbindung von Data Analytics - Fehlender Bezug zu Geschäftsprozessen und Projekt-Outcome

UF = Unternehmensführung DA = Data-Analytics-Abteilung

Bild 4-3: Empfehlungen zur organisatorischen Verortung von Data-Analytics-Ressourcen in Anlehnung an GAUSEMEIER ET AL. [GDE+19]

Eigenständige Data-Analytics-Abteilung

Die Data-Analytics-Ressourcen werden als eigenständige funktionale Einheit in die Organisation eingegliedert. Dabei werden die Data-Analytics-Ressourcen zentral gesteuert und unterstützen relevante Abteilungen wie bspw. das Produktmanagement. Der zentrale Vorteil einer eigenständigen Data-Analytics-Abteilung ist, dass diese Organisationsform eine Steuerung der Data-Analytics-Ressourcen durch einen dedizierten Data-Analytics-Manager ermöglicht. Darüber hinaus ermöglicht eine eigenständige Data-Analytics-Abteilung den Aufbau einheitlicher Analysestandards und Prozesse. Insgesamt bekommt die Data-Analytics-Abteilung eine zentrale strategische Funktion im Unternehmen.

Eine eigenständige Data-Analytics-Abteilung ist insbesondere dann geeignet, wenn eine hohe Datenkomplexität vorliegt. Eine hohe Datenkomplexität erfordert spezifische Data-Analytics-Kompetenzen, die in einer eigenständigen Abteilung systematisch aufgebaut werden können. Darüber hinaus eignet sich eine eigenständige Data-Analytics-Abteilung bei einer hohen Vergleichbarkeit der Produkte im Feld. Die Produkte erzeugen vergleichbare Daten bzw. stellen vergleichbare Anforderungen an die Produktplanung. Bei einer hohen Vergleichbarkeit der Produkte ist es möglich, Data-Analytics-Ressourcen stärker zu zentralisieren und Data-Analytics-Vorhaben zentral durchzuführen. Zu berücksichtigen ist jedoch, dass eine eigenständige Abteilung mit hohen Kosten einhergeht, da eigene administrative Strukturen sowie Führungspositionen geschaffen werden müssen.

Funktionale Eingliederung

Bei einer funktionalen Eingliederung werden Data-Analytics-Ressourcen in bestehende Planungs- und Entwicklungsorganisationen eingegliedert. Zur Gewährleistung von kurzen Entscheidungswegen und einem effizienten Einsatz von Data-Analytics-Ressourcen wird empfohlen die Ressourcen möglichst nah an der Produktplanung einzugliedern [SG16]. Die Verwendung bestehender, administrativer Strukturen gilt als zentraler Vorteil, da diese kosteneffizient und koordinativ umzusetzen sind.

Eine funktionale Eingliederung ist insbesondere dann geeignet, wenn eine eher geringe Datenkomplexität vorliegt. Bei einer geringen Datenkomplexität sind keine hoch spezifischen Kenntnisse zur Aufbereitung und Analyse der relevanten Daten notwendig. Zudem geht eine geringe Datenkomplexität mit einem eher geringen Ressourceneinsatz einher. Zu beachten ist jedoch, dass eine funktionale Eingliederung der Data-Analytics-Ressourcen zu einem „Silodenken“ führen kann. Dies erschwert es eine abteilungsübergreifende Perspektive einzunehmen. Sobald mehrere Business Units in einem Unternehmen jeweils eigene Data-Analytics-Ressourcen funktional in ihre bestehenden Abteilungen eingliedern, stellt sich diese Lösung als ineffizient dar.

Data Analytics als Stabstelle

Data Analytics wird als Stabstelle in die Organisation eingebunden. Organisational ist die Stabstelle direkt der Unternehmensführung untergeordnet, wobei sie bspw. das Produkt-

management unterstützt. Der zentrale Vorteil einer Stabstelle ist die kosteneffiziente Implementierung im Unternehmen. Es werden keine umfangreichen administrativen Strukturen notwendig. Zudem ermöglicht eine Stabstelle einen engen Austausch mit der Unternehmensführung, sodass die Sichtbarkeit innerhalb des Unternehmens erhöht wird.

Stabstellen sind insbesondere bei einer eher geringen Datenkomplexität und einem damit einhergehenden geringeren Ressourcenbedarf geeignet. Zudem ist eine Stabstelle bei einer hohen Vergleichbarkeit der Produkte im Feld geeignet, da die Datenanalysen zentralisiert erfolgen können. Des Weiteren eignet sich eine Stabstelle insbesondere bei der Erprobung von unterschiedlichen Projekten. Zu berücksichtigen ist jedoch, dass Stabstellen eher punktuell in die Produktplanung eingebunden werden. Dadurch ist diese Funktion nicht in reguläre Geschäfts- und Produktplanungsprozesse eingebunden, wodurch z. B. relevante Daten falsch interpretiert werden können.

4.4 Incentivierung der Kunden für die Datenbereitstellung

Die Voraussetzung für eine Betriebsdaten-gestützte Produktplanung bilden Betriebsdaten, die seitens der Kunden zur Verfügung gestellt werden. Zur Sicherstellung des Datenzugangs und der Akzeptanz hinsichtlich der Datenanalyse gilt es den Kunden zu incentivieren. Ein Fehlen geeigneter Incentives bzw. Mehrwerte für den Kunden senkt die Bereitschaft bzw. den Anreiz zur Datenbereitstellung [MMD+19], [WSK+17], [HHW+17]. Insbesondere die Bedenken der Kunden müssen minimiert werden. Es muss bspw. ein sicherer Datentransfer sowie eine sichere Datenspeicherung gewährleistet werden [MMD+19], [PH14]. Darüber hinaus müssen Vorbehalte hinsichtlich der Datenübertragung abgebaut werden; beispielsweise kann dem Kunden gegenüber gewährleistet werden, dass er nicht überwacht wird [HHW+17].

Zunächst wurden Kundenbedenken und -wünsche mithilfe einer Recherche identifiziert; diese wurde im Rahmen eines Workshops mit interdisziplinären Experten aus Forschung und Praxis validiert und ergänzt. Bild 4-4 zeigt die konsolidierte Liste von Bedenken und Wünschen. Kunden haben Bedenken durch die Datenbereitstellung die Kontrolle über die Datenverwendung zu verlieren; insbesondere ein Mehrwert durch die Datenbereitstellung kann diesen Bedenken entgegenwirken. Im weiteren Vorgehen wurden die gesammelten Aspekte in Anforderungen überführt. Dabei konnten insgesamt drei Kategorien identifiziert werden: Personen-, prozess- und unternehmensbezogene Anforderungen. **Personenbezogene** Anforderungen beziehen sich bspw. auf einzelne Mitarbeiter. Es existieren Bedenken hinsichtlich der Weitergabe von sensiblen Daten, anhand derer Rückschlüsse auf einzelne Mitarbeiter gezogen werden können. Dem entgegen steht das Potential, die Mitarbeiter über die Auswertung der Daten besser qualifizieren zu können. Dies stellt einen entscheidenden Wettbewerbsfaktor dar [AAE+19], [JGP+15], [AF18], [Com19], [MV16]. Während die personengebundenen Anforderungen sich auf einzelne Mitarbeiter beziehen, bestehen auch **prozessbezogene** Bedenken. Durch die Datenbereitstellung kön-

nen Rückschlüsse auf Fertigungsprozesse gezogen werden; somit sind Betriebsgeheimnisse gefährdet. Demgegenüber wird eine Transparenz über die Anlagenzustände erzeugt, sodass bestehende Prozesse mit geringem Aufwand verschlankt werden können [BFG+17], [AH16]. Die letzte Kategorie stellt **unternehmensbezogene** Anforderungen dar. Insbesondere über den Datenzugriff und die Datenverwendung sind Unsicherheiten vorhanden. Kunden und Anwender müssen von der IT-Sicherheit überzeugt sein, sowohl was den Bereich Systemzuverlässigkeit anbelangt als auch den Bereich Systemschutz [GSM+19], [JGP+15], [VDM18], [GSK+14], [BFG+17], [AF18], [AAE+19]. Kunden versprechen sich durch die Datenbereitstellung und -analyse jedoch auch eine Steigerung der Produktverfügbarkeit und -performance.

Konsolidierte Liste von Bedenken und Wünschen (Auszug) Kunden haben Bedenken durch die Datenbereitstellung... <ul style="list-style-type: none"> ▪ Betriebsgeheimnisse zu verlieren ▪ sensible Daten an Dritte zu vergeben ▪ ... Kunden wünschen sich durch die Datenbereitstellung: <ul style="list-style-type: none"> ▪ die Verfügbarkeit der Produkte zu erhöhen ▪ die Weiterentwicklung bestehender Produkte in Form e und/oder der nächsten Generation ▪ ... 		
Anforderungsliste (Auszug) Datenbereitstellung seitens des Kunden		
F/W	Nr.	Anforderungen

	4	Personenbezogene Wünsche
F	F	Bessere Qualifizierung der Mitarbeiter
F	F	Kundenindividuelle Produkthanpassungen

Bild 4-4: Ableitung von Anforderungen aus den Bedenken und Wünschen des Kunden (Auszug)

Die identifizierten Anforderungen wurden im weiteren Vorgehen zu Maßnahmen überführt. Maßnahmen beschreiben konkrete Aktivitäten; sie verdeutlichen an welcher Stelle es einen Hebel setzen zu gilt [GDE+19]. Dabei konnte die Strukturierung der Anforderungen in personen-, prozess- und unternehmensbezogene Aspekte übernommen werden. Dementsprechend bilden die Kategorien den Rahmen für den Maßnahmenkatalog. Darüber hinaus wurden die Maßnahmen in einen zeitlichen Horizont eingeteilt. Dabei wurde zwischen kurz-, mittel- und langfristig unterschieden. Bild 4-5 zeigt einen Auszug des Maßnahmenkatalogs zur Incentivierung der Kunden für die Datenbereitstellung.

Maßnahmenkatalog (Auszug)	
Incentivierung der Kunden für die Datenbereitstellung	
Unternehmensbezogene Maßnahmen	Zeitl. Horizont
Geheim	
Vergün	
Technis	
Produkt	
Kunder	
Prozes	
...	
Kosten	

Maßnahmenkatalog (Auszug)	
Incentivierung der Kunden für die Datenbereitstellung	
Personenbezogene Maßnahmen	Zeitl. Horizont
Schulung	
Baukas	
Kosten	

Maßnahmenkatalog (Auszug)		
Incentivierung der Kunden für die Datenbereitstellung		
Prozessbezogene Maßnahmen	Zeitl. Horizont	
Anonym	Kostengünstige Nachrüstung	mittelfristig
Rechtli	Programmorschläge	mittelfristig
...	Gewährleistung der Datenverschlüsselung	kurzfristig
Versch	Einführung von Sicherheitsstandards	langfristig
	Limitation v. Dauer u. Ort der Datenspeicherung	mittelfristig
	Verwendung von unternehmenseigenen Servern	langfristig
	Transparente Datenweitergabe	kurzfristig
	Demonstratoren als Praxisbeispiele	kurzfristig
	...	

Bild 4-5: Maßnahmenkatalog zur Incentivierung der Kunden für die Datenbereitstellung

Literatur zu Kapitel 4

- [AAE+19] ABEL-KOCH, J.; AL OBAIDI, L.; EL KASMI, S.; ACEVEDO, M. F.; MORIN, L.; TOP-CZEWSKA, A.: GOING DIGITAL - The Challenges Facing European SMEs – European SME Survey 2019. Europa, 2019
- [AF18] APPELFELLER, W.; FELDMANN, C.: Die digitale Transformation des Unternehmens – Systematischer Leitfadens mit zehn Elementen zur Strukturierung und Reifegradmessung. Springer Berlin, 2018
- [AH16] ABRAMOVICI, M.; HERZOG, O. (Hrsg.): Engineering im Umfeld von Industrie 4.0 – Einschätzungen und Handlungsbedarf. acatech Studie, Herbert Utz Verlag München, 2016
- [BFG+17] BUCHHOLZ, B.; FERDINAND, J.-P.; GIESCHEN, J.-H.; SEIDEL, U.: Digitalisierung industrieller Wertschöpfung – Transformationsansätze für KMU – Eine Studie im Rahmen der Begleitforschung zum Technologieprogramm AUTONOMIK für Industrie 4.0 des Bundesministeriums für Wirtschaft und Energie. Berlin, 2017
- [Com19] Branchenbericht Maschinenbau in Deutschland. Frankfurt am Main, 2019
- [ERT16] EKMAN, P., RAGGIO, R. D., & THOMPSON, S. M.: Service network value co-creation: Defining the roles of the generic actor. Industrial Marketing Management, 2016
- [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
- [GSK+14] GEISSBAUER, R.; SCHRAUF, S.; KOCH, V.; KUGE, S.: Industrie 4.0 – Chancen und Herausforderungen der vierten industriellen Revolution. Deutschland, 2014

- [GSM+19] GEISSBAUER, R.; SCHRAUF, S.; MORR, J.-T.; WUNDERLIN, J.; KRAUSE, J. H.; ODENKICHEN, A.: Digital Product Development 2025 – Agile, Collaborative, AI Driven and Customer Centric, 2019
- [HHW+17] HÖHN, M.; HOLLAUER, C.; WILBERG, J.; KAMMERL, D.; MÖRTL, M.; OMER, M.: Investigation usage data Support in development processes - a case study. In: ICED (Hrsg.): Proceedings of the 21st International Conference on Engineering Design (ICED17), Vol. 7: Design Theory and Research Methodology –(ICED) 2017 21-25 Aug, Vancouver. IEEE Vancouver, Canada, 2017, S. 91–100
- [JGP+15] JÄGER, J. M.; GÖRZIG, D.; PAULUS-ROHMER, D.; SCHATTON, H.; BAKU, S.; WESKAMP, M.; LUCKE, D.: Industrie 4.0 – Chancen und Perspektiven für Unternehmen der Metropolregion Rhein-Neckar – Studie im Auftrag der Industrie- und Handelskammern Rhein-Neckar, Pfalz und Darmstadt Rhein Main Neckar erstellt durch das Fraunhofer-Institut für Produktionstechnik erstellt durch das Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA. Deutschland, 2015
- [MMD+19] MASSMANN, M.; MEYER, M.; DUMITRESCU, P. D.-I. R.; ENZBERG, S. von; FRANK, M.; KOLDEWAY, C.; KÜHN, D.-I. K.; REINHOLD, J.: Significance and Challenges of Data-driven Product Generation and Retrofit Planning. In: Putnik, G. D. (Hrsg.): 29th CIRP Design Conference 2019, 08-10 May 2019, Póvoa de Varzim, Portugal. 84, Elsevier B.V., 2019, S. 992–997
- [MV16] Zukunftsperspektive deutscher Maschinenbau – Erfolgreich in einem dynamischen Umfeld agieren. Berlin, 2014
- [PH14] PORTER, M. E.; HEPPELMANN, J. E.: Wie smarte Produkte den Wettbewerb verändern. Harvard Business Manager, (12), 2014
- [SG20] SCHREYÖGG, G., & GEIGER, D.: Organisation: Grundlagen moderner Organisationsgestaltung. Mit Fallstudien. Springer-Verlag, 2020
- [VDM18] Industrie 4.0 konkret – Lösungen für die industrielle Praxis. Frankfurt am Main, 2018
- [Wit20] WITTE, F.: Verantwortlichkeiten, Zuständigkeiten und Kommunikation. In: Strategie, Planung und Organisation von Testprozessen. Springer. Pp. 165-176. 2020.
- [WSK+17] WILBERG, J.; SCHÄFER, F.; KANDBINDER, P.; HOLLAUER, C.; OMER, M.; LINDEMANN, U.: Data Analytics in Product Development: Implications from Expert Interviews. In: IEEM; Institute of Electrical and Electronics Engineers; IEEE International Conference on Industrial Engineering & Engineering Management (Eds.): 2017 IEEE International Conference on Industrial Engineering & Engineering Management –(IEEM) 2017 10-13 Dec, Singapore. IEEE Piscataway, NJ, 2017, pp. 818–822

5 IT-Unterstützung

Thomas Dickopf, Christo Apostolov, Ian Altmann, Andreas Saum

Die Etablierung der Betriebsdaten-gestützten Produktplanung in produzierenden Unternehmen erfordert eine Vielzahl an Veränderungen in den Dimensionen Mensch, Technologie und Organisation. Einerseits fehlt es an geeigneten Methoden und Vorgehensweisen zur Durchführung einer systematischen Betriebsdaten-gestützten Produktplanung. Zum anderen erfordert die Umsetzung eines solchen Ansatzes eine sozio-technische Betrachtung. So ergeben sich neue Prozesse, die Auswirkung auf die Organisationsstrukturen haben. Miteinhergehend werden neue Rollen und Kompetenzen für die Entwicklungsorganisation benötigt. Entlang des Lebenszyklus heutiger komplexer technischer Systeme kommt bereits eine Vielzahl an IT-Werkzeugen zum Einsatz. Für eine Betriebsdaten-gestützte Produktplanung müssen diese in eine durchgängige IT-Landschaft integriert werden. Somit wird eine technische Datendurchgängigkeit gewährleistet und benötigte Daten werden ermittelt, erfasst, analysiert und nutzbar gemacht. Dazu wird in diesem Beitrag sowohl die technische Realisierung zur Unterstützung der Faktoren Organisation und Mensch anhand des in Kapitel 3 vorgestellten Referenzprozesses für die Betriebsdaten-gestützte Produktplanung vorgestellt, gefolgt von einem technischen Konzept und dessen Umsetzung zur Gewährleistung von Datendurchgängigkeit zwischen Produktplanung, -entwicklung (PLM) und -nutzung (IoT) im Sinne des Closed-Loop-Engineerings. Die Realisierung beider Konzepte erfolgt unter Anwendung der Fachanwendungen der CONTACT Elements Plattform.

5.1 Werkzeugseitige Unterstützung des Referenzprozesses

Während der Referenzprozess das methodische und prozessuale Vorgehen zur Betriebsdaten-gestützten Produktplanung unterstützt, dient CONTACT Elements als werkzeug-technische Unterstützung insbesondere über die dort angebotenen Funktionalitäten für das Projektmanagement. Das CONTACT Elements Fachobjekt Projekt bildet den Referenzprozess ab und bündelt gleichzeitig sämtliche projektbezogenen Informationen. Dieses wurde als ausprägbare Projektvorlage angelegt, sodass das Projekt eine kontinuierliche Wiederverwendung findet. Die im Referenzprozess dargestellte Struktur aus Haupt- und Subprozessen (vgl. Kapitel 3) wird über die Projektstruktur in CONTACT Elements abbildet und in einen zeitlichen Kontext gesetzt. Bild 5-1 veranschaulicht die Darstellung der Haupt- und Subprozesse des Referenzprozesses. Ferner werden die einzelnen Prozesse in Form eines Terminplans dargestellt, sodass die Projektaufgaben zeitlich verortet und in Relation zueinander gesetzt werden können.

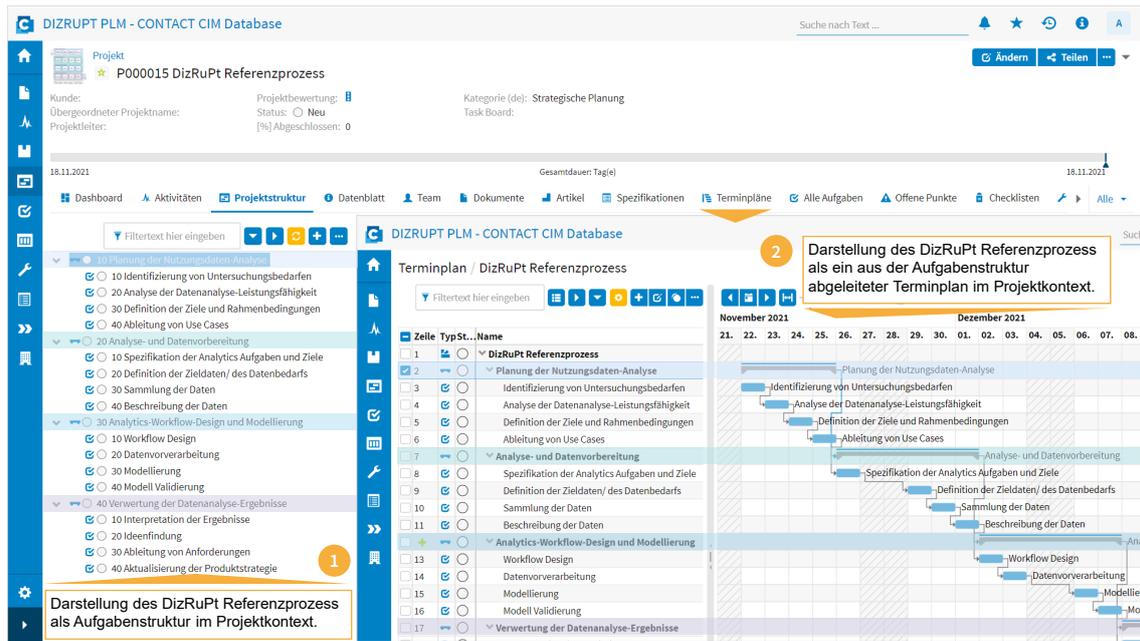


Bild 5-1: Darstellung der Haupt- und Subprozesse des Referenzprozesses in CONTACT Elements

Für die Umsetzung der Haupt- und Subprozesse für die Betriebsdaten-gestützte Produktplanung wurden Rollenprofile definiert, benötigte Kernkompetenzen verortet und die Verantwortlichkeiten der definierten Rollen für die einzelnen Subprozesse anhand der RACI-Methode identifiziert (vgl. Kapitel 4). Die neudefinierten Rollenprofile wurden in CONTACT Elements als weitere Projektrollen angelegt und dem Projekt hinzugefügt (s. Bild 5-2).

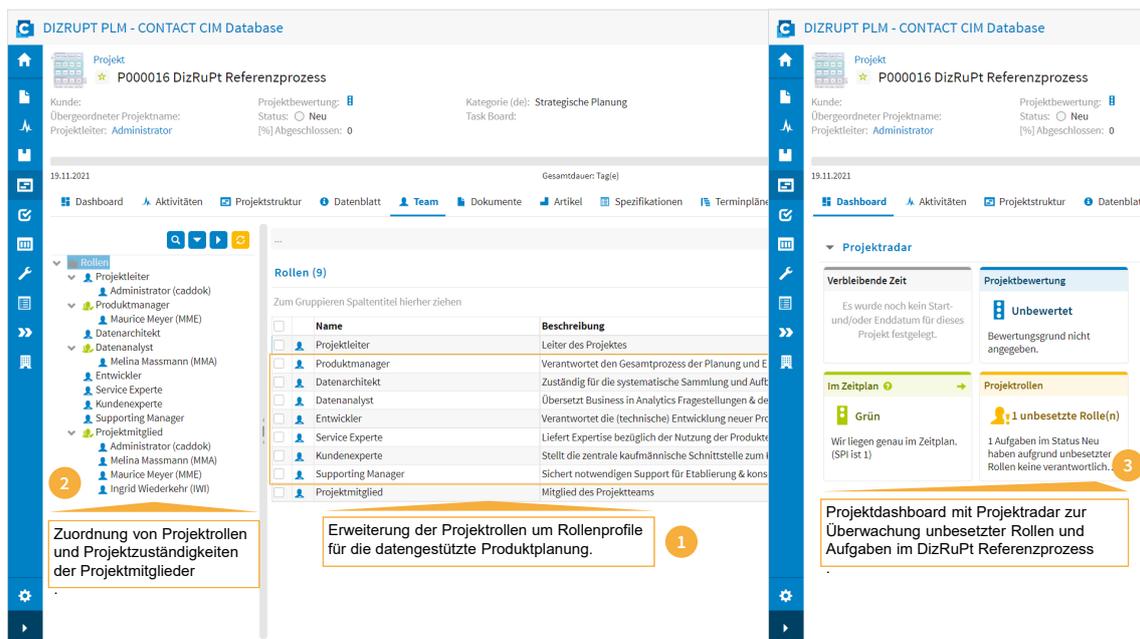


Bild 5-2: Integration von Rollenprofilen in den in CONTACT Element abgebildeten DizRuPt Referenzprozess

Bei der Neuanlage von Projektaufgaben ist es in CONTACT Elements verpflichtend die Verantwortlichkeit für diese zu bestimmen: Diese kann über Projektrollen oder Projektmitglieder erfolgen. Für die werkzeugseitige Unterstützung des Referenzprozesses erfolgte hier eine Zuordnung der neu angelegten Rollenprofile zu den in der Projektstruktur als Projektaufgaben definierten Subprozesse (s. Bild 5-1). Die Zuordnung erfolgte anhand der durch die RACI-Methode identifizierten Verantwortlichkeiten (*R-Responsible*). Für die Ausführung eines Projekts in CONTACT Elements sollte jeder definierten Projektrolle mindestens ein Projektmitglied zugeordnet werden. Das Projektradar auf dem Projektdashboard warnt automatisiert über Aufgaben mit Verantwortlichkeiten unbesetzter Rollen (s. Bild 5-2).

Zur Bearbeitung einzelner Subprozesse des Referenzprozesses stehen dem Anwender verschiedene Methoden zur Verfügung. Die werkzeugseitige Unterstützung dieser Methoden kann in CONTACT Elements über verschiedene Wege aktiv oder passiv erfolgen. Eine passive Unterstützung kann bspw. über das Bereitstellen und Managen von Methodentemplates in Form gängiger Office-Anwendungen erfolgen. Vorgefertigte Templates können im Projekt an einer Projektaufgabe als Dateien in einer Dokumentenvorlage hinterlegt werden. Mit Beginn dieser Aufgabe kann automatisiert oder manuell aus der Dokumentenvorlage ein neues Dokument erzeugt werden, welches anschließend gleichzeitig im Projektkontext verwaltet und bearbeitet werden kann. Nachteil dieses Ansatzes ist, dass zwar das Gesamtergebnis im Projektkontext als Dokument verwaltet und referenziert werden kann, einzelne Ergebnisse in den Dateien jedoch nicht direkt als separates Dateinobjekt weiterverarbeitet werden können.

Für die Methoden des ersten Hauptprozesses wurde eine aktive Unterstützung durch CONTACT Elements gewählt. Auf Basis des CONTACT Elements Spezifikationsmoduls wurden für die verschiedenen Methoden Spezifikationsvorlagen generiert, welche in der Plattform bearbeitet und ausgefüllt werden können. Ein wesentlicher Vorteil ist, dass die erstellten Inhalte als einzelne Spezifikationsobjekte erzeugt und verwaltet werden und somit im Gegensatz zur Dateiverwaltung als einzelne Ergebnisse in der Plattform weiterverwendet werden können. Zusätzlich bietet die CONTACT Elements Fachanwendung der Universal Classification hier die Möglichkeit, die einzelnen Objekte mit weiteren Merkmalen, wie bspw. Bewertungskriterien, anzureichern. Bild 5-3 verdeutlicht die werkzeugseitige Unterstützung der im Subprozess Analytics-Bedarfsanalyse genutzten Methoden zur Sammlung und Bewertung von Stakeholder-Requirements in CONTACT Elements anhand der genannten Fachanwendungen.

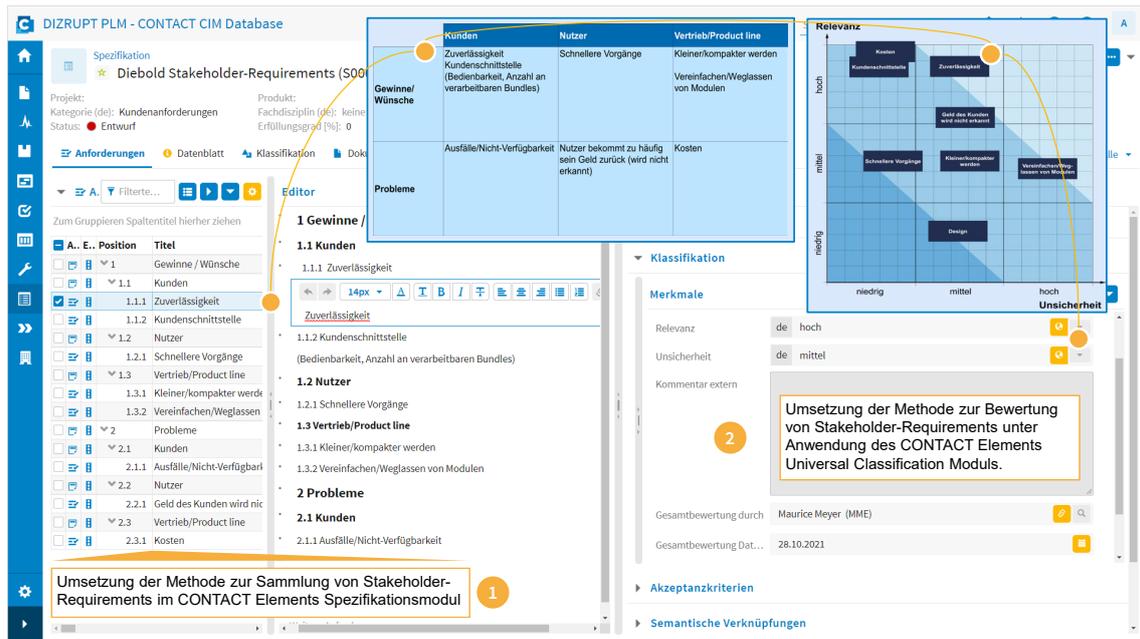


Bild 5-3: Werkzeugseitige Unterstützung der Methoden des Referenzprozesses in CONTACT Elements

Zur Bearbeitung und Visualisierung einzelner Methoden und Prozessergebnisse wurde ein Canvas-Modul entwickelt, welches auf dem CONTACT Elements Spezifikationsmodul aufbaut. Bild 5-4 zeigt exemplarisch das Ergebnis des ersten Hauptprozesses in Form des Use-Case-Steckbriefes. Dabei wurde die Spezifikations- und Canvas-Darstellung verwendet.

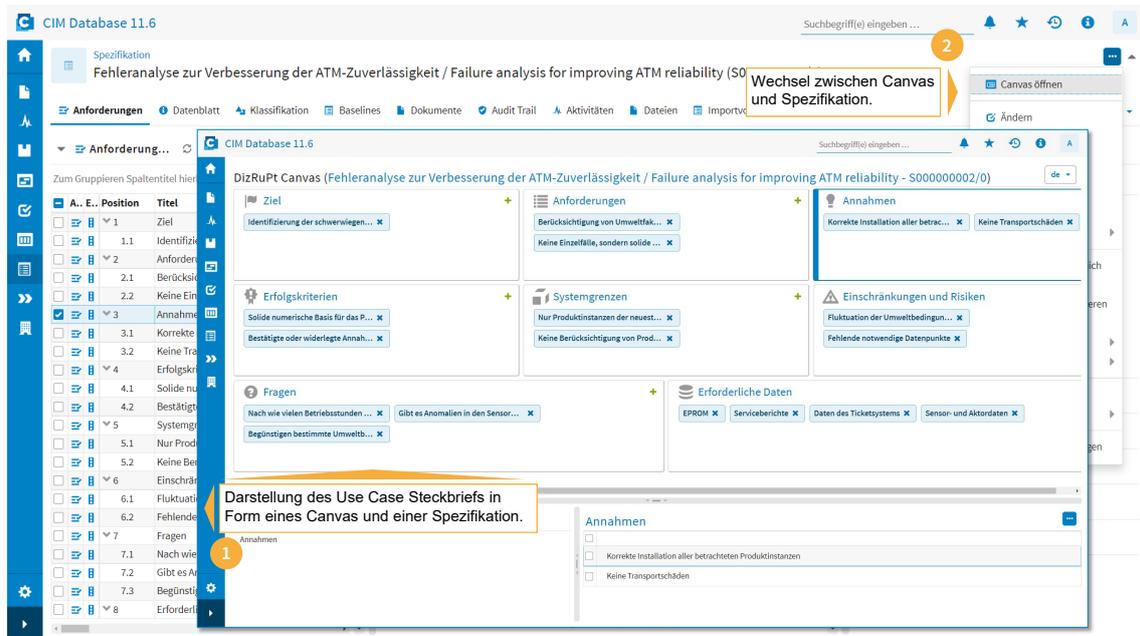


Bild 5-4: Ergebnisdarstellung des Referenzprozesses als Spezifikation und Canvas in CONTACT Elements

5.2 Datendurchgängigkeit entlang des Closed-Loop-Engineering-Ansatzes

Das folgende Kapitel beleuchtet ein Konzept und dessen technische Realisierung zur durchgängigen Datenvernetzung entlang der Lebenszyklusphasen der Produktplanung, -entwicklung, und -nutzung. Das Konzept greift die bidirektionale Integration zwischen PLM- und IoT-Systemen auf und bildet das Daten-Backend-System zur Betriebsdaten-gestützten Produktplanung. Für die prototypische Umsetzung wurde ebenfalls auf die CONTACT Elements Plattformtechnologie zurückgegriffen, wobei die CONTACT CIM Database das PLM-System und die CONTACT Elements for IoT das IoT-System repräsentieren. Der Closed-Loop-Engineering-Ansatz ist in Anlehnung an den Referenzprozess in vier wesentliche Phasen eingeteilt. Dieser wird im Folgenden durch einzelne Schrittfolgen dargestellt und mit methodischen Ansätzen untermauert. Bild 5-5 bildet das Gesamtkonzept ab.

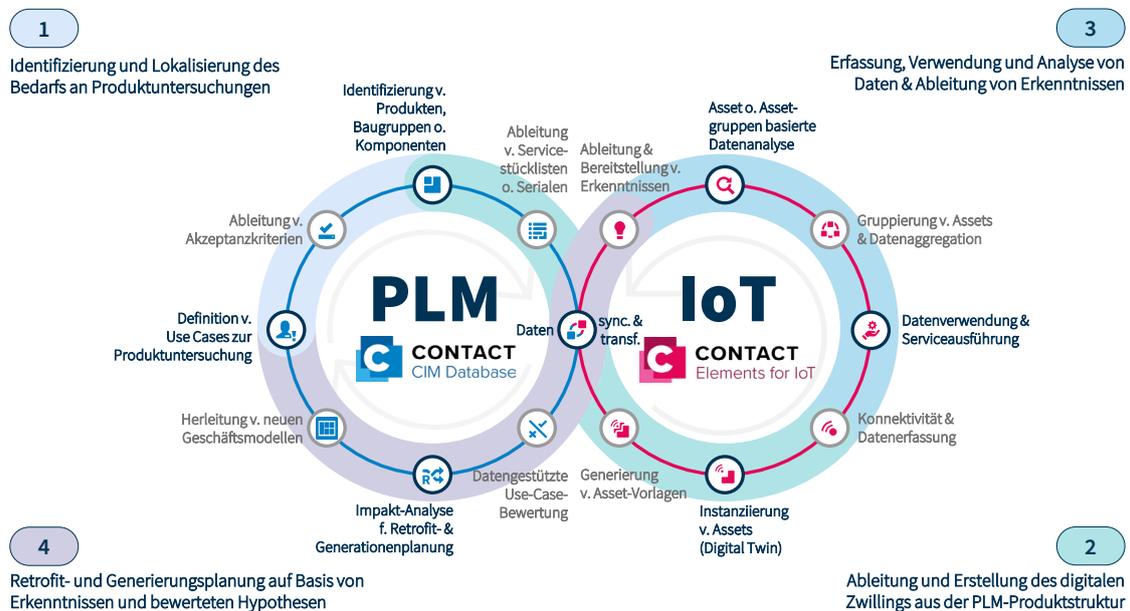


Bild 5-5: DizRuPt Closed-Loop-Engineering-Konzept

5.2.1 Identifizierung und Lokalisierung des Bedarfs an Produktuntersuchungen

Im Rahmen der Identifikation und Lokalisierung des Produktuntersuchungsbedarfs (s. Bild 5-5) erfolgt die Analyse und Lokalisierung von Problemen an vorhandenen Produkten bzw. Produktgenerationen. Ausgehend von der Definition von Use Cases zur Produktuntersuchung, die auf bekannten Problemen und Optimierungspotentialen aufbauen, werden Annahmen in Form von Hypothesen getroffen. Diese zeigen mögliche Ursachen und Lösungen oder sind in Form von Fragestellungen definiert. In Abhängigkeit der Produktkomplexität beziehen sich diese Annahmen oder Fragestellungen auf das Gesamt-

produkt, entsprechende Baugruppen oder Einzelteile. Vor dem Hintergrund der Rückverfolgbarkeit und Datendurchgängigkeit werden diese miteinander verknüpft. Zur Bewertung bzw. Beantwortung der definierten Hypothesen bzw. Fragestellungen unterstützen bewertbare Akzeptanzkriterien. Diese können sich auf das gesamte Produkt oder Teilaspekte beziehen. Die erste Phase des Closed-Loop-Engineering-Ansatzes hat somit eine enge Verzahnung mit dem ersten Hauptprozess des Referenzprozesses (vgl. Abschnitt 3.1). Die werkzeugseitige Unterstützung für die Definition und das Management der Use Cases zur Produktuntersuchung, deren Hypothesen, Fragestellungen und möglichen Akzeptanzkriterien erfolgt in CONTACT CIM Database auf Basis des Spezifikationsmoduls (s. Bild 5-6).

The screenshot displays the CONTACT CIM Database 11.6 interface. The main window shows a specification for 'LASCO Hydraulische Schmiedehammer HO-U Produktuntersuchungen (S000000000/0)'. The 'Editor' panel contains a list of use cases and their descriptions, such as '1 Fehleranalyse bei Maschinenstillständen' and '2 Umsetzung einer Produktdigitalisierung'. The 'Details' panel shows an acceptance criterion table with columns for 'A. E.', 'Beschreibung...', 'Ist-Wert', 'Maßeinheit', and 'Zielbereich'. The 'Semantics' panel shows a hierarchical tree of product components, with 'Fehleranalyse bei Maschinenstillständen' linked to '000723/ Hauptpumpe_Baugrupp' and '000728/ Bar und Einsatz_Baugru'. Three callouts provide additional context: 1. 'Strukturierte Spezifikation für Produktuntersuchungen auf Basis von Anwendungsfällen und Fragestellungen bzw. Hypothesen zum zu untersuchenden Produkt inklusive Rich Text Editor zum direkten erstellen und bearbeiten.' 2. 'Verfeinerung der Hypothesen und Fragestellung um numerisch bewertbare Akzeptanzkriterien.' 3. 'Semantische Verknüpf zum zu untersuchenden Produkt, deren Baugruppen oder Artikel.'

Bild 5-6: Definition und Management von Use Cases zur Produktuntersuchung, Hypothesen, Fragestellungen und möglichen Akzeptanzkriterien in CONTACT CIM Database

5.2.2 Ableitung und Erstellung des digitalen Zwillings aus der PLM-Produktstruktur

Die Erhebung und Verwaltung von Daten ist für eine Betriebsdaten-gestützte Produktplanung unerlässlich. Jedoch stellt diese eine Vielzahl produzierender Unternehmen vor eine Herausforderung. Produzierende Unternehmen müssen einerseits dazu befähigt werden, Daten aufzunehmen und zu verwalten. Andererseits müssen diese Daten in Form eines Digitalen Zwillings abgebildet werden, sodass sowohl Hersteller als auch Endanwender des Produkts einen Nutzen ableiten können. Große Nutzenpotentiale lassen sich aus den Daten der Produktnutzung ableiten, wenn sie in Relation zu Produktinformationen aus dessen Entwicklung und Produktion gesetzt werden können.

In der zweiten Phase des Closed-Loop-Engineering-Ansatzes wird die Datenkontinuität zwischen Entwicklungs- und Betriebsphase des Produkts sichergestellt, indem der Digitale Zwilling (im IoT-Kontext als Asset bezeichnet) aus der PLM-Produktstruktur abgeleitet wird. Im Rahmen des Projektes wurde hierfür eine generische Stücklistenstruktur (BOM) erarbeitet. Dabei bildet die Engineering-Stückliste (eBOM) den As-Designed-Zustand des Produktes ab. Auf Basis dieser Stückliste kann sowohl der weitere Weg in die Produktion (As-Built) als auch in den Digitalen Zwilling spezifiziert werden (As-Maintained). Für den Digitalen Zwilling lässt sich eine Service-Stückliste (sBOM) ableiten (s. Bild 5-7). Diese sBOM entspricht einer Aufschlüsselung aller servicerelevanten Teile eines Produktes während dessen Betrieb. Darauf aufbauend werden folgend die einzelnen Positionen der sBOM bzgl. ihrer IoT-Relevanz klassifiziert (s. Bild 5-8). Hier erfolgt einerseits die Identifikation, welche Komponenten als Assets abgebildet werden sollen und somit die Möglichkeiten bereitstellen, Nutzungsdaten zu erfassen und Business-Anwendungen (bspw. die Ableitung von Servicefällen oder das Ansteuern von Workflows) auf ihnen auszuführen. Andererseits erfolgt die Identifikation von Bauteilen, welche zusätzlich Service-kritische Komponenten darstellen, da es sich bei diesen um Verschleiß- oder Reparaturteile handelt.

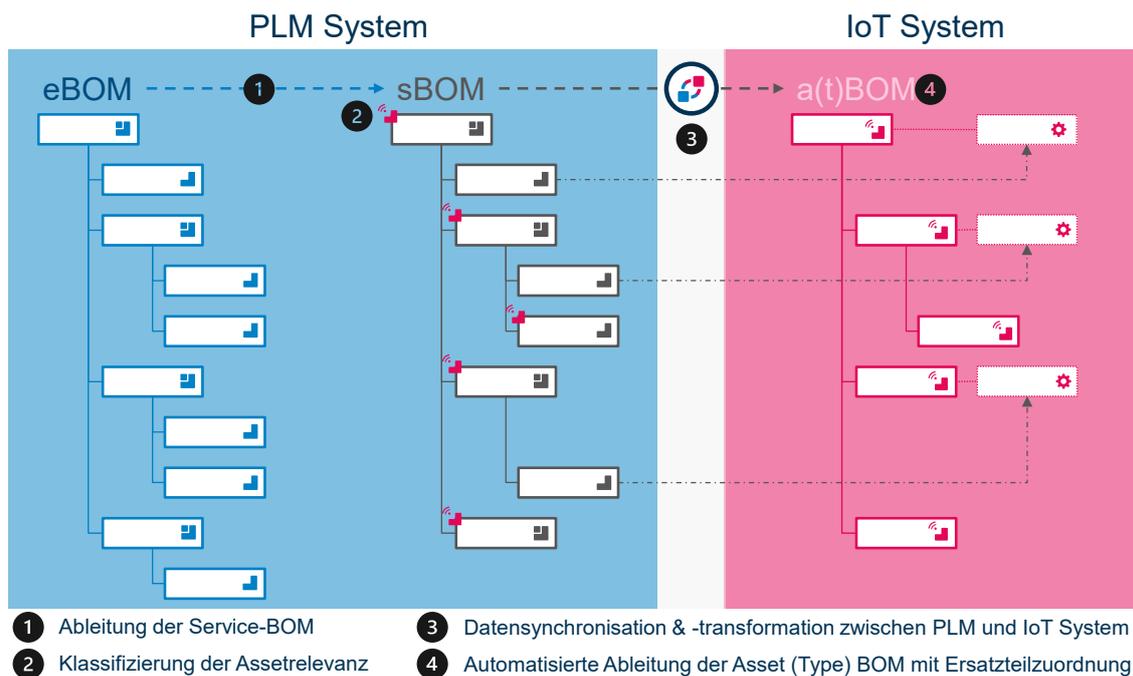


Bild 5-7: Konzept zur Ableitung von Asset-Komponentenstrukturen aus Engineering-Stücklisten

Mit Freigabe der sBOM für das IoT-System, erfolgt die Synchronisation der sBOM, wodurch eine Asset-Typ-Komponentenstruktur (atBOM) abgeleitet wird. Der Asset-Typ beschreibt in CONTACT Elements for IoT eine Asset-Vorlage. Der Asset-Typ referenziert dabei das virtuelle Produktmodell im PLM-System und erweitert es um IoT-anwen-

dungsspezifische Aspekte, wie bspw. die Verarbeitung von Ereignis- und Telemetriedaten oder die Generierung von Servicefällen. Mit der Instanziierung des Assets im IoT-System aus dem Asset-Type und der Konnektivität sowie dem Datenempfang vom realen Asset erfolgt schließlich der Übergang in die nächste Phase des Closed-Loop-Engineering-Ansatzes. Die CONTACT CIM Database bietet die Möglichkeit spezifische Stücklisten wie bspw. die Fertigungsstückliste oder Servicestückliste aus bestehenden Stücklisten wie der Konstruktionsstückliste auszuleiten. Unterstützend wirkt hierbei das Fachmodul des xBOM-Managers, da dieses Folgeprozesse im Produktlebenszyklus bildet und die Datendurchgängigkeit gewährleistet. Bild 5-8 verdeutlicht die Anwendung des xBOM-Managers zur Ableitung der Service-Stückliste aus der zugrunde liegenden Konstruktionsstückliste. Ferner ist eine Klassifizierung der einzelnen Komponenten hinsichtlich ihrer IoT-Relevanz über die Ändern-Maske möglich. Dabei kann die Entscheidung getroffen werden, ob eine Komponente bei der Synchronisation ins IoT-System als Asset-Typ und oder Ersatzteil transformiert werden soll.

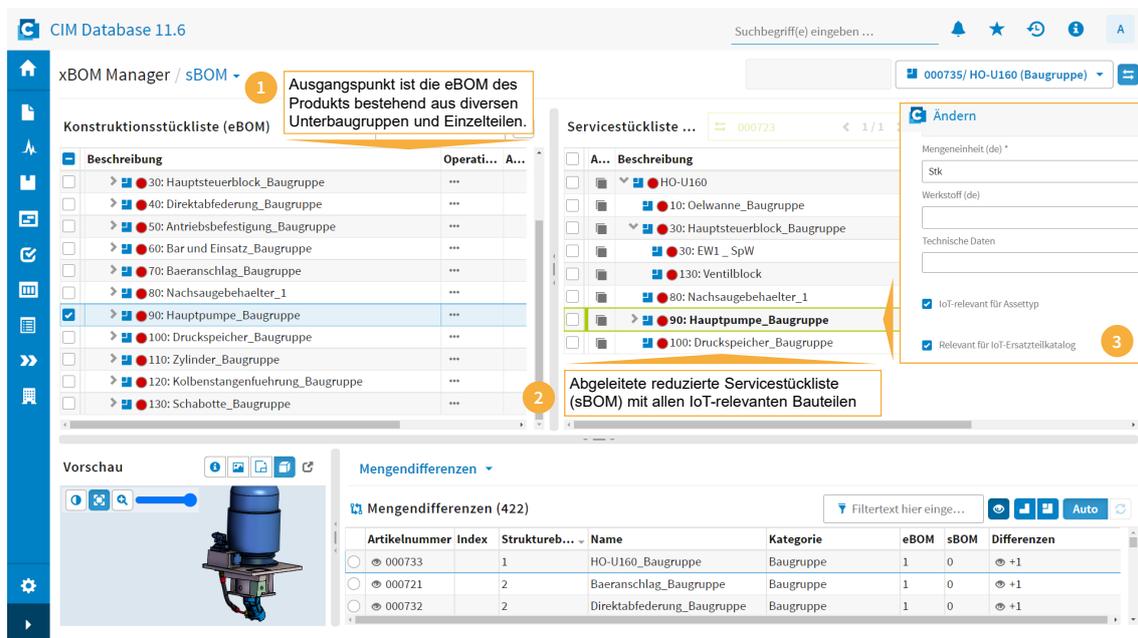


Bild 5-8: Ableitung der sBOM und Klassifizierung der IoT-Relevanz in CONTACT CIM Database

Bild 5-9 verdeutlicht den aus dem im PLM-System verwalteten virtuellen Produktmodell abgeleiteten Asset-Typen eines Produkts, welcher durch die Synchronisation zwischen CONTACT CIM Database und CONTACT Elements for IoT automatisiert generiert wurde. Dieser ermöglicht, neben der durch die Synchronisation generierten Auflistungen an untergeordneten Asset-Typen oder Ersatzteilen, IoT-relevante Funktionalitäten des Assets vorzudefinieren. Darunter fallen bspw. Funktionalitäten wie die Definition von Zeitreihendaten, Ereignissen, Kennzahlen oder Dashboards. Zusätzlich bietet der Asset-Type einen Überblick über alle aus ihm ausgeprägten Assets samt ihres Betriebszustandes.

The screenshot displays the CONTACT Elements for IoT interface. The top part shows the 'Komponenten' (Components) view for the asset type 'HO-U160 (AT-000185)'. A table lists sub-components with columns for 'Untergeordneter Asset-Typ', 'Verbauungskennzeichen', 'Namenszusatz', 'Beim Ausprägen i...', and 'Angelegt von'. A callout box (1) notes that components are derived based on IoT-relevant parts from the PLM system. A second callout box (2) indicates the extension of asset types with IoT-relevant functionalities. The bottom part shows the 'Assets' view, displaying a table of instantiated assets with columns for 'A.. A.. ID', 'Name', 'Aktuell in Betrieb', 'Kategorie', and 'Asset-Typ'. A callout box (3) provides an overview of assets instantiated from the asset type. The right sidebar shows the configuration settings for the asset type, including various attributes and data points.

Bild 5-9: Instanziierung des Assets aus dem Asset Typ in CONTACT Elements for IoT

5.2.3 Erfassung, Verwendung und Analyse von Daten und Ableitung von Erkenntnissen

Mit der Anbindung des realen Assets an das IoT-System und der Erfassung der Daten aus der Produktnutzung erfolgt der Übergang in die dritte Phase des Closed-Loop-Engineering-Ansatzes. Je nach Definition der Konnektivität zwischen reellem und digitalem Asset können sowohl Telemetriedaten, welche kontinuierlich in einer Zeitreihendatenbank gespeichert werden, als auch definierte Ereignisse mit genauen Zeitwerten und zusätzlichen Parametern generiert und an das IoT-System übertragen werden.

Am Asset vordefinierte Ereignisse werden auf Basis vorhandener Daten in den Zeitreihendatenbanken oder durch zeitbasierte Regeln automatisiert ausgeführt werden. Ausgelöste Ereignisse können sowohl Operationen und Prozesse im Zusammenhang mit den im IoT-System angebotenen Business-Anwendungen ansteuern (bspw. die Erstellung von Servicefällen, Workflows oder neuen Geschäftsobjekten) als auch der Produkte im Feld. Beispielhaft genannt ist die Abfrage der aktuellen Hard- und Softwareversionen oder die gezielte Steuerung bestimmter Produktfunktionalitäten.

Bild 5-10 verdeutlicht die Datenerfassung, -visualisierung und -verarbeitung in CONTACT Elements for IoT. Durch die Ansteuerung von Business-Anwendungen im IoT-System entstehen neue, relevante Betriebsdaten.

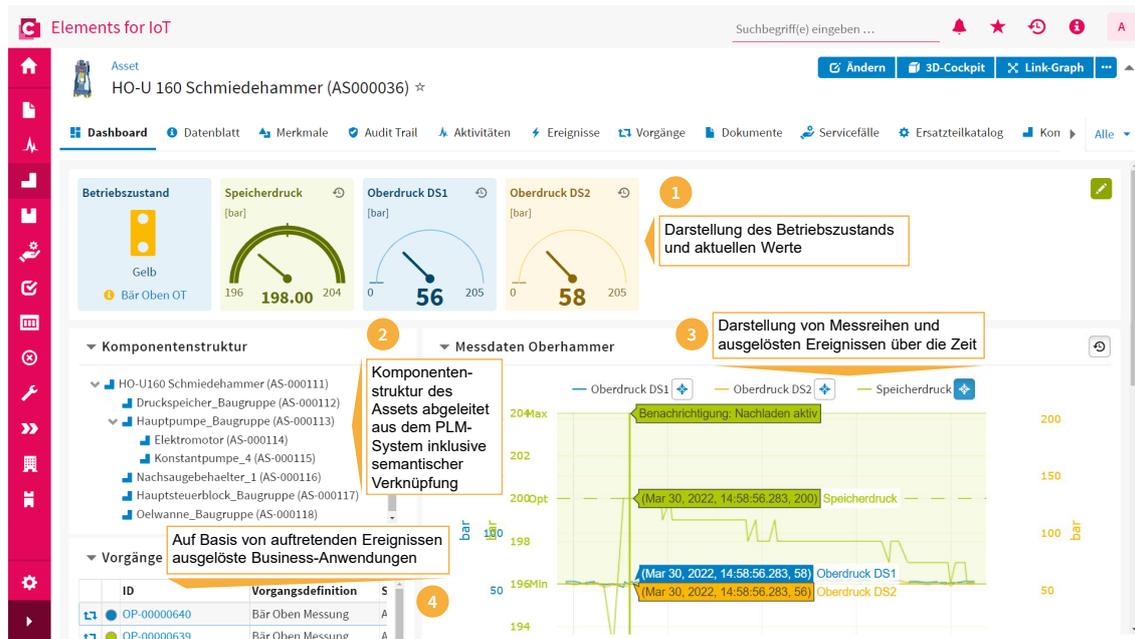


Bild 5-10: Asset-Monitoring über Dashboards in CONTACT Elements for IoT

Die Datenanalyse für die Betriebsdaten-gestützte Produktplanung bezieht sich sowohl auf einzelne Assets als auch auf die aggregierte Datenbasis gleichartiger Assets, welche in Asset-Gruppen zusammengefasst werden. Das Verfahren der Datenanalyse und die dafür erforderliche IT-Infrastruktur hängen von den vorhandenen Daten, dem Use Case und dessen Zielsetzung ab. So können bspw. KPIs bei einer deskriptiven Datenanalyse direkt im IoT-System auf Basis der gespeicherten Telemetriedaten oder ausgelösten Events berechnet werden.

Für explorative Datenanalysen (z. B. Anomalie-Erkennungen), werden entsprechende Datenanalyse-Werkzeuge oder -Module in die IoT-Plattform eingebunden oder die Daten über offene Schnittstellen (z. B. REST) bereitgestellt. Bei großen Datenmengen und kurzen Übertragungsraten ist bspw. eine Datenverdichtung sinnvoll oder die Ergebnisübertragung einer vorgelagerten Analyse (z. B. auf einem Edge Device) an das Asset. Bild 5-11 verdeutlicht im IoT System aufgenommene Datenmengen eines Produkts im IO- (in Ordnung) und NIO-Zustand (nicht in Ordnung), welche beispielsweise für explorative Datenanalysen hinsichtlich des Aufbaus von Anomalie-Erkennungsmodellen als wesentliche Grundlage genutzt werden.

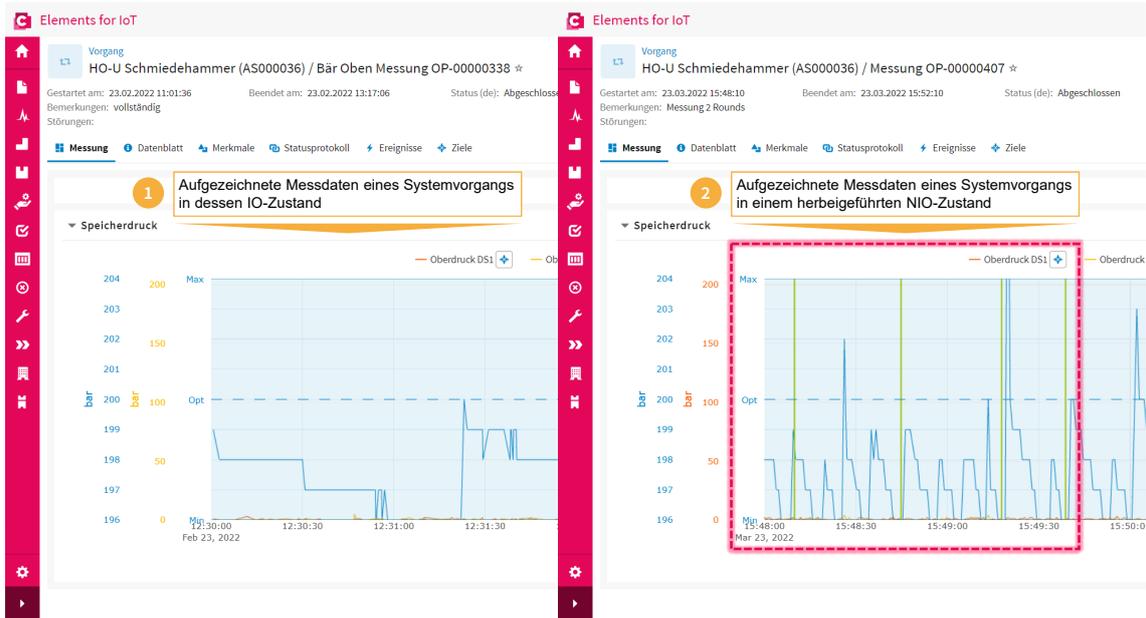


Bild 5-11: Aufgezeichnete Messdaten und deren Visualisierung in CONTACT Elements for IoT

5.2.4 Retrofit-Generierungsplanung auf Basis von Erkenntnissen und bewerteten Hypothesen

Auf Basis der im IoT-Kontext erfolgten Analyse und gewonnenen Erkenntnissen wird die letzte Phase des Closed-Loop-Engineering-Ansatzes zur Betriebsdaten-gestützten Produktplanung gestartet (s. Bild 5-5). Diese besitzt Integrationspunkte zum vierten Hauptprozess des Referenzprozesses und befasst sich mit der Rückführung und der Verarbeitung der Erkenntnisse in das PLM-System. Das Erkenntnisobjekt (s. Bild 5-12) stellt eine Erweiterung der CONTACT Elements for IoT Plattform dar, welches im Kontext von Assets oder Asset-Gruppen angelegt wird und in Zeitreihendaten wie auch Analyseergebnissen, Anomalie-Scores oder KPIs seine Begründung findet. Eine Detaillierung kann über einen Freitext, referenzierte Zeitabschnitte in Diagrammen, Klassifizierungen oder zugefügte Dokumente erfolgen. Mit Freigabe des angelegten Erkenntnisobjekts erfolgt die Synchronisation ins PLM-System zu dessen Weiterverwendung. Die Rückverfolgbarkeit zwischen den Datenobjekten (Produktmodell im PLM-System, Asset-Typen, Assets im IoT-System) ist sichergestellt. Demzufolge ist bei einer Synchronisation der Erkenntnisse nachzuvollziehen auf welche Objekte sich im PLM-System bezogen wird. So können bspw. die Akzeptanzkriterien der aufgestellten Hypothesen in den Use Cases der Produktuntersuchung auf Basis der gewonnenen Erkenntnisse datenbasiert bewertet (s. Bild 5-12).

The screenshot displays the CONTACT Elements for IoT interface. On the left, a sidebar contains navigation icons. The main area is split into two panes. The left pane shows a 'Finding' object with ID 'C00000004: Nachladeintervalle Speicherdruck'. It includes a 'Beschreibung' section with a callout box (1) stating: 'Definition des Erkenntnisobjekts mit Stammdaten, textueller Beschreibung und zugehörigen Dateien im IoT System.' The right pane shows a 'Spezifikation' object for 'LASCO Hydraulische Schmiedehammer HO-U Produktuntersuchung'. It features a table for 'Akzeptanzkriterien (1)' with the following data:

A.. E.. Beschreibung ...	Ist-Wert	Maßeinheit	Zielbereich	Zuletzt bewertet am
Nachladeintervall...	33	%	>=75	11.04.2022 09:49

Below the table is a callout box (2) stating: 'Anwendung des Erkenntnisobjekts im PLM-System zur Bewertung von Akzeptanzkriterien und den dazugehörigen Hypothesen der Produktuntersuchung.' Further down, there is a section for 'Semantische Verknüpfungen (3)' with a table of semantic links.

Bild 5-12: Erkenntnisobjekt in CONTACT Elements for IoT

Aufgrund der Datendurchgängigkeit und der Verlinkung zwischen den verschiedenen Informationen zu einem Produkt im PLM-System werden die Auswirkungen einer Änderung auf die anderen Objekte eines Produktmodells analysiert und ein entsprechender Änderungsprozess (Engineering-Change) eingeleitet. Bild 5-13 verdeutlicht die Darstellung eines Engineering-Change in CONTACT CIM Database inklusive der zu ändernden Bauteile und Begleitdokumente sowie das dazugehörige prozessuale Vorgehen als Workflow.

The screenshot shows the CONTACT CIM Database interface for an Engineering Change (EC) with ID 'EC00000001: Produktverbesserung - Funktionsverbesserung'. The top section provides details about the change, including the change number, phase (ECO), status (Genehmigung), and category (Standard). Below this, there is a navigation pane on the left and a main workspace. The workspace displays a workflow diagram for the change process, starting with 'Änderungsausführung einleiten...' and 'Bauteile optimieren', followed by 'Information' and 'Prüfung der Änderung'. A callout box (1) on the left states: 'Übersicht über alle zu ändernden und geänderten Bauteile samt Begleitdokumente auf Basis der Impact-Analyse.' A callout box (2) at the bottom of the workflow states: 'Geleiteter Änderungsprozess zur Optimierung der Bauteile auf Basis von Workflows.'

Bild 5-13: Engineering-Change zur Produktoptimierung in CONTACT CIM Database

Neben der Impact-Analyse und den daraus resultierenden Optimierungseffekten für die neuen Produktgenerationen oder die Nachrüstung bereits im Einsatz befindlicher Produkte lassen sich aus den gewonnenen Erkenntnissen auch neue Geschäftsmodelle ableiten beziehungsweise diesbezüglich aufgestellte Use Cases zur Produktuntersuchung und deren Annahmen bestätigen und konkretisieren.

5.2.5 Datenmodell des Closed-Loop-Engineering-Ansatzes für die Betriebsdaten-gestützte Produktplanung

Im Rahmen des gezeigten Closed-Loop-Engineering-Ansatzes wurde ein methodisches Vorgehen und dessen werkzeugtechnische Umsetzung auf Basis der CONTACT Elements Plattform zur Sicherstellung der Datendurchgängigkeit und Datenrückverfolgbarkeit für die Betriebsdaten-gestützte Produktplanung vorgestellt. Einen Überblick über die dazu genutzten Datenobjekte und deren Zusammenhänge liefert das in Bild 5-14 dargestellte Datenmodell, welches sich in Planungs- und Entwicklungsphase (PLM-System – CONTACT CIM Database) sowie Betriebsphase (IoT-System – CONTACT Elements für IoT) unterteilen lässt.

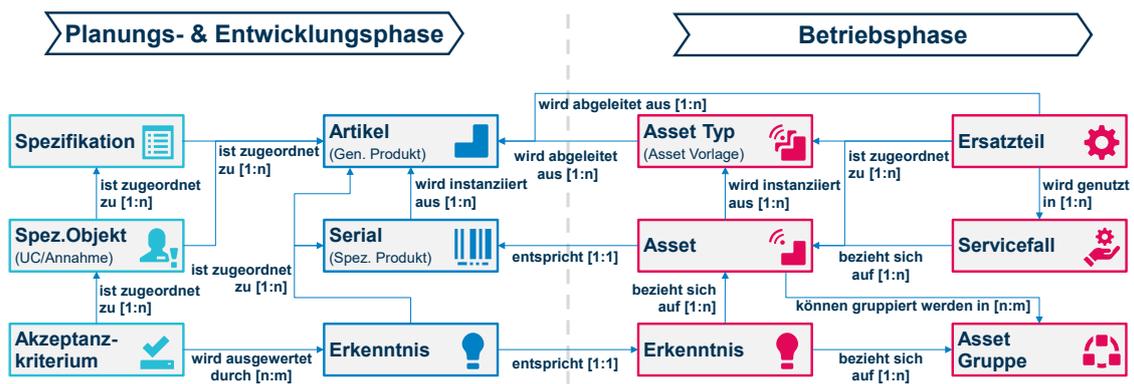


Bild 5-14: Datenmodell des Closed-Loop-Engineering-Ansatzes für die Betriebsdaten-gestützte Produktplanung

6 Einblicke in die Anwendungsbeispiele des Forschungsprojekts „DizRuPt“

Moritz Schilling, Daniel Panick, Ingo Kaiser, Thomas Dickopf, Stefan Wecker, Olaf Knospe

Im Rahmen des Projekts wurden die entwickelten Methoden und Prozesse mit vier Anwenderunternehmen (LASCO Umformtechnik GmbH, Weidmüller Interface GmbH & Co. KG, Diebold Nixdorf Systems GmbH und Westaflexwerk GmbH) validiert. Die Anwenderunternehmen unterscheiden sich sowohl hinsichtlich der im Projekt betrachteten Produkte als auch der Unternehmensgröße und Organisationsform. Dies führte zu individuellen Ausgangssituationen und unterschiedlichen Herausforderungen bei der Anwendung. Im folgenden Kapitel werden Einblicke in die vier Anwendungsbeispiele gegeben. Diese zeigen, wie die Unternehmen ausgewählten Herausforderungen begegnet sind.

6.1 Anwendungsbeispiel 1: LASCO Umformtechnik GmbH

Die Firma LASCO Umformtechnik GmbH (Fa. LASCO) mit Sitz in Coburg widmet sich seit Gründung im Jahre 1863 der Aufgabe Maschinen und Anlagen im Bereich der Umformtechnik herzustellen. Leistung, Qualität und Fortschritt der Erzeugnisse begründen die weltweite Anerkennung der Fa. LASCO als Technologielieferant und Innovator der Umform- und Baustoffindustrie. Der Fokus gilt dem Bau von Werkzeugmaschinen für die Metallmassiv- und Blechumformung.

Die umfangreiche Produktpalette umfasst u. a. einen hydraulischen Oberdruckhammer (s. Bild 6-1). Dieser zählt zu den energiegebundenen Maschinen und ist, aufgrund seiner besonderen Umformcharakteristik, ein universell einzusetzendes Umformaggregat mit breitem Einsatzspektrum in der Schmiedeindustrie. Die für die Umformung erforderliche kinetische Energie (auch Bewegungsenergie genannt) wird durch die Masse des Hammerbärs in Zusammenspiel mit seiner Fallhöhe (auch Fallenergie bzw. potentielle Energie genannt) und mittels der hydraulischen Oberdruckenergie zur Verfügung gestellt [Her13]. Der Hammerbär ist demnach mit einem Hydraulikzylinder verbunden und wird durch diesen auf- und abgetrieben. Mit mehreren aufeinanderfolgenden Hieben des Hammerbärs (den sog. Hammerschlägen) wird das ca. 1.300 °C heiße Metall so lange umgeformt, bis die gewünschte Geometrie des Schmiedeteils erreicht ist. Dieser Fertigungsprozess induziert bzw. emittiert einen starken Schallwechseldruck, welcher in Form von Erschütterungen in den Maschinenteilen und der Umgebung bemerkbar wird. Aufgrund der prozessbedingten hohen Temperaturen wird der Umgebung zusätzlich Zunder und Staub zugeführt. Wird ein Graphit-Wasser-Gemisch als Trennmittel im Schmiedegeßenk eingesetzt, erhöht sich die relative Luftfeuchtigkeit sowie der Verschmutzungsgrad der Umgebungsluft. Als Folge dieser Effekte sind die Umgebungsbedingungen des Schmiedepro-

zesses nicht optimal für den Einsatz von Messsystemen und Kommunikationstechnologien. Es wurden daher Lösungen erarbeitet, die es ermöglichen, während des Schmiedeprozesses Betriebsdaten aufzunehmen und diese für die Betriebsdaten-gestützte Produktplanung nutzbar zu machen.

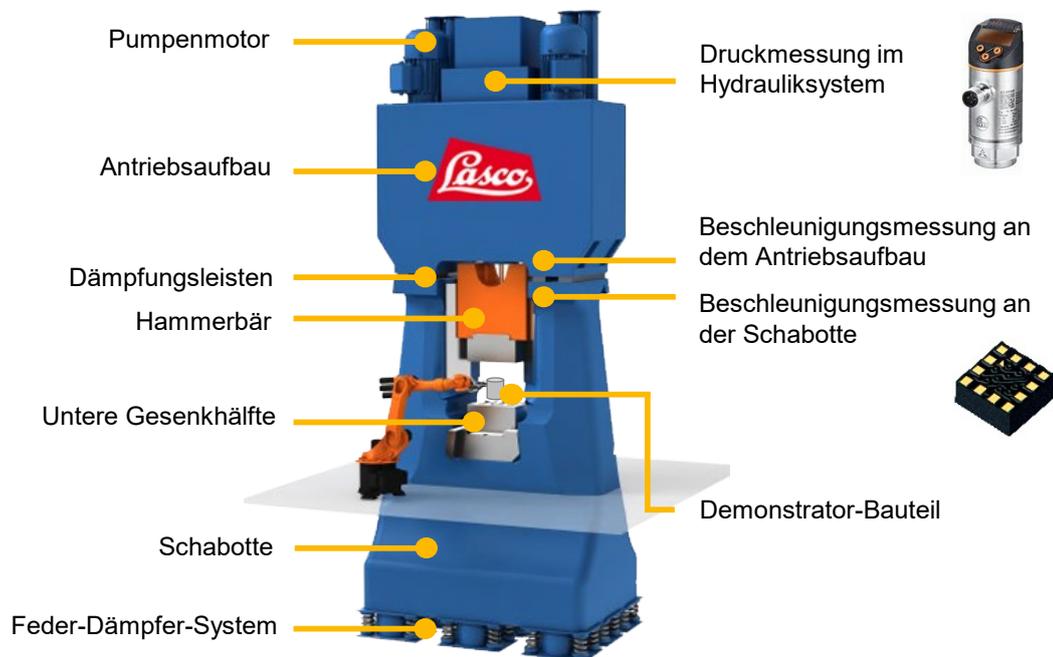


Bild 6-1: Hydraulischer Oberdruckhammer mit angedeutetem Hallenboden sowie Bezeichnung der Hauptkomponenten und umgesetzten Messstellen

6.1.1 Nachrüstung von MEMS-Sensoren zur Messung von Beschleunigungen am Gestell eines Oberdruckhammers

Problematik

Mit den hydraulischen Oberdruckhämern wird ein sehr präziser Energieeintrag zur Fertigung von Schmiedeteilen ermöglicht. Dennoch stellt sich im Rahmen des kontinuierlichen Verbesserungsprozesses fortlaufend die Frage, ob das Maximum der Performance bspw. in der Antriebsauslegung bereits erreicht ist oder ob weitere Potentiale in der Produktplanung und -entwicklung existieren.

Im Arbeitsablauf des Oberdruckhammers wird der Hammerbär mit definierter Energie und Zeit beschleunigt, um mit einer eingestellten Aufschlaggeschwindigkeit auf das Schmiedeteil zu treffen und Umformenergie einzubringen. Die spezifisch ausgelegte Masse der Schabotte (s. Bild 6-1) wirkt dem Hammerschlag entgegen und bestimmt den größtmöglichen Energieeintrag. Kann der Energieeintrag nicht vollständig vom Umformvorgang aufgenommen werden, wird die überschüssige Energie an die Schabotte weitergeleitet. Damit eine Übertragung dieser Energie in die Umgebung verhindert wird, ist die Schabotte und somit der gesamte Oberdruckhammer auf einem Feder-Dämpfer-System

gelagert, das die überschüssige Energie in einem vertikalen Ausschwingvorgang absorbiert. Für einen präzisen Energieeintrag in das Schmiedeteil ist es erforderlich, dass der Ausschwingvorgang vor jedem erneuten Hammerschlag beendet ist und sich das Feder-Dämpfer-System in einem energetischen Ruhzustand befindet.

Bisher bestand noch keine Möglichkeit, die Auslegung der Anlagenkomponenten sowie das Nutzungsverhalten der Anwenderunternehmen mit digitalen Messdaten von Anlagen aus dem Feld zu bewerten und in die strategische Produktplanung einfließen zu lassen. Somit können potentielle Optimierungen, bspw. von der Auslegung der Schabotte, des Feder-Dämpfer-Systems und der Schockfestigkeit der Antriebe, nicht anhand von Messdaten aus im Feld befindlichen Anlagen erfolgen, sondern müssen auf der Basis von Erfahrungswissen und Anwenderfeedback erarbeitet werden.

Zielsetzung

Vor diesem Hintergrund verfolgte die Fa. LASCO das Ziel, Beschleunigungssensoren am hydraulischen Oberdruckhammer nachzurüsten und Beschleunigungsdaten während des Schlag- und Ausschwingvorgangs aufzunehmen. Mit diesen sollten Erkenntnisse über das Schwingverhalten des Oberdruckhammers gewonnen werden, um die Auslegung der Schabotte, des Feder-Dämpfer-Systems sowie des Motors in zukünftigen Produktgenerationen zu optimieren. Wichtig war dabei, dass das Messsystem autark von der Anlagensteuerung betrieben werden kann und gegenüber den anspruchsvollen Umgebungsbedingungen resistent ist. Besonders bei der Adaption der Sensoren musste eine Lösung gefunden werden, welche ohne Veränderungen an der Schabotte eine sichere Anbringung gewährleistet sowie den auftretenden Erschütterungen bei der Ausführung der Hammerschläge dauerhaft standhält. Dies ist notwendig, um eine Nachrüstung bei bereits im Feld befindlichen Anlagen ohne aufwändige Umbaumaßnahmen zu ermöglichen.

Vorgehensweise

Unter Verwendung des Konzeptes zur Sensornachrüstung (vgl. Abschnitt 3.2.3) wurde ein von der Maschinensteuerung autark arbeitendes Messsystem entwickelt.

Zum Messen der prozessbedingten Beschleunigungen und folglich der auf die Maschine (Feder-Dämpfer-System und Motoren) wirkenden Schwingungen, wurden Sensoren an dem Antriebsaufbau sowie an der Schabotte (s. Bild 6-1) montiert. Zur Montage wurde sich – aufgrund der starken Erschütterungen und der Nachrüstbarkeit – für eine Schraubverbindung entschieden, welche bestehende Gewindebohrungen am Oberdruckhammer verwendet. Der Aufwand für die Montage konnte so auf ein Minimum reduziert werden und ermöglicht bei Bedarf eine einfache Demontage des Messsystems. Die Sensoren wurden von der Fachhochschule Südwestfalen (FH SWF) als performantes Micro-Electro-Mechanical System (MEMS) ausgelegt, welches eine dynamische Messung von Beschleunigungen bis zu ± 64 g triaxial ermöglicht. Bild 6-2 zeigt das Messsystem mit der zugehörigen Kommunikationstechnik. Im Vergleich zu bekannten Industriestandards zur

Messung von Beschleunigungen, bspw. piezoelektrische Sensoren mit eingebauter Impedanzwandler-Elektronik (IEPE), bestehen bei den MEMS-Sensoren zahlreiche Möglichkeiten, die Kommunikations- und Auswerteelektronik auf Platinen-Ebene zu integrieren. Dies kann zu einem erheblichen Kostenvorteil in Bezug auf die Sensorik führen. Damit einhergehend besteht ein hohes Miniaturisierungspotential. Trotz der geringen Größe der MEMS-Sensoren ermöglichen diese eine triaxiale Beschleunigungsmessung. Diese erfolgt mit einer maximalen Abtastrate von 8,5 kHz je Achse und einer Auflösung von 16 Bits bzw. 0,0020 g/LBS. Die von der FH SWF entwickelte Sensor-Platine besaß eine Größe von 15 mm x 25 mm x 7 mm und beinhaltete alle erforderlichen Komponenten. Dazu zählten Widerstände, Kondensatoren, Spannungsregler, Kabeltreiber etc. sowie der MEMS-Sensor. Dieser Aufbau wird nachfolgend unter der Bezeichnung „Sensor“ zusammengefasst.

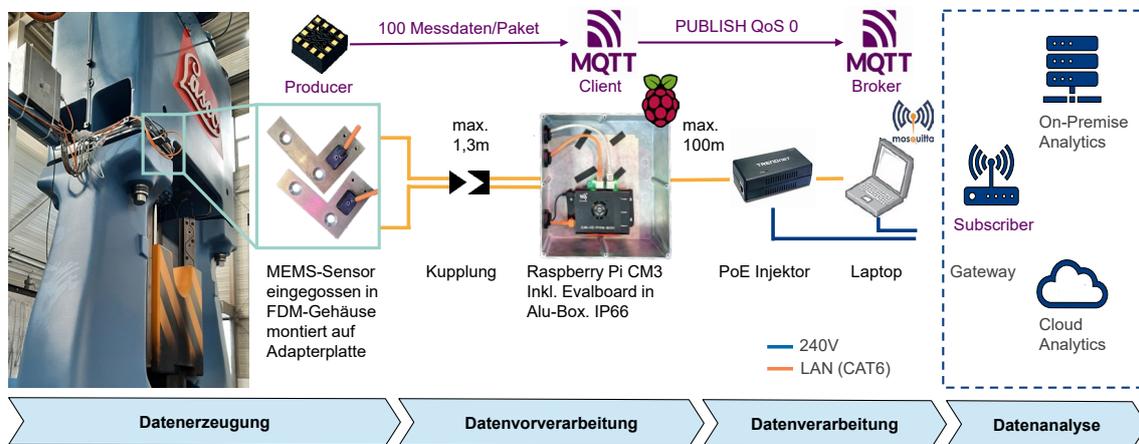


Bild 6-2: Aufbau Messsystem zur Beschleunigungsmessung am Oberdruckhammer

Aufgrund der hohen Leistungsfähigkeit in den Bereichen Übertragungsgeschwindigkeit, Zykluszeit und Fehlererkennung wurde die Datenübertragung mittels Industrial Ethernet (Standard Cat-6-Kabel) realisiert. Ein weiterer Vorteil der gewählten Datenübertragungstechnik war die Stromversorgung des Messsystems mittels „Power over Ethernet“ (PoE). Dadurch konnte auf zusätzliche Stromleitungen verzichtet werden. Die Stromversorgung der Sensoren stellten spezielle Spannungsregler auf der entwickelten Sensorplatine sicher. Zusätzlich wurde eine Leitungslänge von 1,3 m zur nachgelagerten Verarbeitungselektronik realisiert. Aufgrund der rauen Umgebungsbedingungen des Schmiedeprozesses und zur Gewährleistung einer stabilen Schraubverbindung wurde die Sensorplatine in ein aus FDM-gedrucktes Gehäuse eingesetzt, welches mit Polyurethan (PU)-Harz ausgegossen wurde. Das PU-Harz diente aufgrund seiner 65Shore-A Härte zusätzlich als Schockabsorber und realisierte gleichzeitig eine hohe Schutzklasse. Die Verarbeitungselektronik wurde durch ein Aluminiumgehäuse vor Staub und Schmutz geschützt. Die „on the edge“ betriebene Verarbeitungselektronik beinhaltete eine Verteilerplatine, welche die eingehenden Ethernet-Kabel aufnimmt, sowie einen Raspberry Pi CM3 (RPi) als Mikrocomputer. Dabei diente der RPi als Speicherpuffer für die aufgenommenen Messdaten.

Zur Übertragung der Sensordaten von der Verarbeitungselektronik bis zum nachgeschalteten PC wurde das Message Queuing Telemetry Transport (MQTT) Protokoll verwendet. Das MQTT-Protokoll war zum einen sehr performant, da es besonders für die Übertragung einer großen Anzahl von kleinen bis mittleren Datenmengen sehr gut geeignet ist. Zum anderen ermöglichte es eine gute Interoperabilität mit nachgelagerten Integrationsplattformen, wie z. B. einer Cloud-Anwendung. Die Daten wurden innerhalb des Protokolls unter dem eingestellten Topic im Raw-Binary-Format in einem Paket vom Sensor an den Nachrichtenserver (MQTT-Broker) gesendet. Der auf dem PC instanziierte Broker erhielt bspw. bei einer eingestellten Abtastrate von 25 s^{-1} alle vier Sekunden ein Paket von 100 Messdaten je Sensor. Jeder Datensatz enthielt die X-, Y-, Z-Beschleunigung im Datentyp float (single precision) und zusätzlich einen Zeitstempel im Datentyp Uint32. Der Zeitstempel war in Verbindung mit der eingesetzten Dienstgüte wichtig, um eventuell verloren gegangene Datenpakete erkennen zu können. Anschließend wurden die aufgenommenen Daten pro Sensor über ein Python-Skript in eine Textdatei im Comma-separated-values (CSV)-Format geschrieben. Das CSV-Format wurde zur Speicherung bzw. zum Austausch der aufgezeichneten Messdaten gewählt, da es sich dabei um ein bewährtes Standardformat handelt. Es war mit einem geringen Aufwand in der Datenanalyse handhabbar und ließ sich mit Excel als Datenverknüpfung sowohl einfügen als auch visualisieren. Für eine nachgelagerte Datenanalyse bot es sich an, das autarke Messsystem über ein Gateway als On-premise oder Cloud-Lösung zu betreiben und an verschiedene Plattformen anzubinden.

Resultat

Im Anschluss an die Nachrüstung des Beschleunigungssensors wurden zunächst mehrere Abtastraten untersucht, damit das Schwingverhalten des Oberdruckhammers hinreichend genau und mit einer möglichst geringen Datenmenge seitens der Sensoren aufgezeichnet wird. Zur Realisierung des Umformwiderstands wurde ein Demonstrator-Bauteil in Form eines Zylinders (100 mm x 170 mm) aus Blei verwendet. Aufgrund der sicherzustellenden Datenintegrität und des Datenschutzes erfolgte die Analyse der Daten in einer On-premise-Lösung. Bild 6-3 zeigt die aufgenommene Beschleunigung (Y-Achse) für einen Ausschwingvorgang der Schabotte nach einem Hammerschlag für die repräsentativen Abtastraten von 3,2 kHz (oben) und 1,6 kHz (unten).

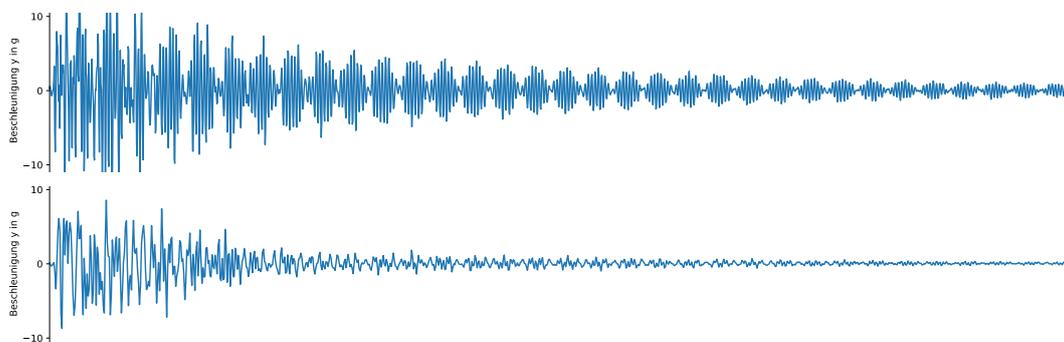


Bild 6-3: Vergleich zwischen der Abtastrate 3,2 kHz (oben) und der Abtastrate 1,6 kHz (unten) an Schabotte

Nachdem die geeigneten Parameter für den Sensor bestimmt wurden, erfolgte die eigentliche Untersuchung des Schwingverhaltens. Für die Aufnahme der Beschleunigungsdaten an den festgelegten Messstellen (Schabotte und Antriebsaufbau) wurden zwei Szenarien identifiziert, um konkrete Erkenntnisse über das Schwingverhalten zu gewinnen:

- (1) **Zur Erfassung der maximalen Beschleunigungen:** Drei Prellschläge auf ein bereits umgeformtes Demonstrator-Bauteil (höherer Umformwiderstand als im Originalzustand) bei 100 % Schlagenergie (31,5 kJ).
- (2) **Zur Erfassung der Entwicklung der Beschleunigungen:** Sechs aufeinanderfolgende Schläge auf ein nicht umgeformtes Demonstrator-Bauteil bei 100 % Schlagenergie.

Innerhalb des ersten Szenarios wurde in der Z-Achse eine maximale Beschleunigung von 10,80 g für den Antriebsaufbau (A) und 41,24 g für die Schabotte (S) aufgezeichnet. Die Z-Achse ist für die Auslegung der Schabotte und des Feder-Dämpfer-Systems ausschlaggebend. Für die Auslegung der Pumpenmotoren sind die Nebenrichtungen (X- und Y-Achse) ebenfalls von Bedeutung. Für die drei Prellschläge auf das bereits umgeformte Demonstrator-Bauteil wurde für die X-Achse eine maximale Beschleunigung von 26,09 g (S) und 1,57 g (A) sowie 32,26 g (S) und 3,74 g (A) für die Y-Achse gemessen. Die aufgenommenen Messwerte werden in Bild 6-4 gezeigt.

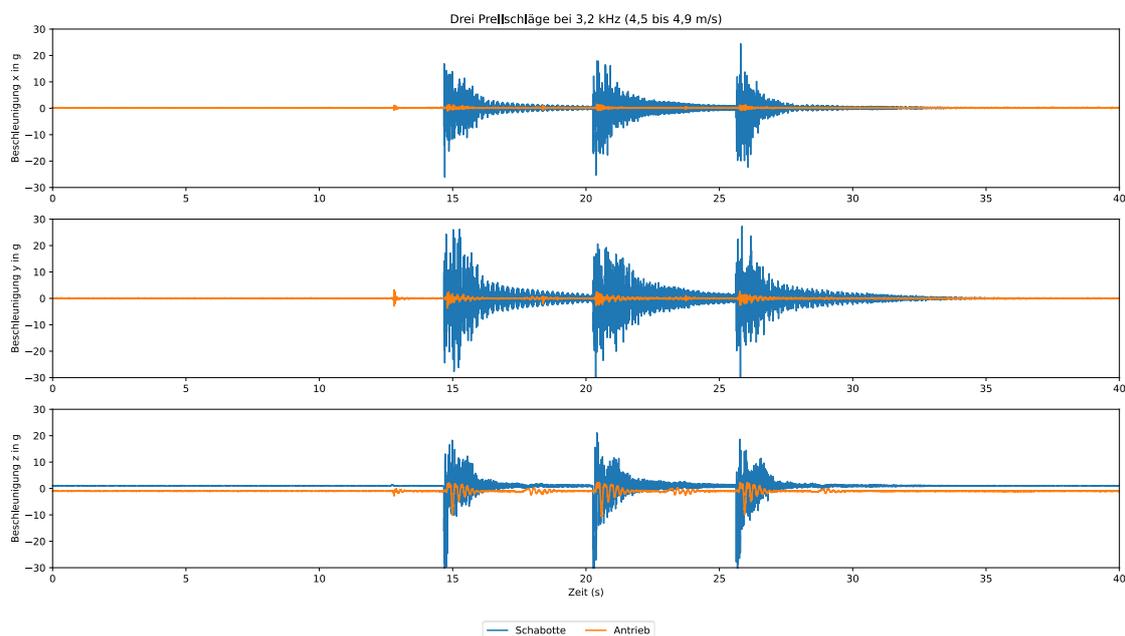


Bild 6-4: Beschleunigungsmessung an der Schabotte (blau) und des Antriebsaufbaus (orange) bei einer Abtastrate von 3,2 kHz (Szenario 1: drei Prellschläge)

Die Ausschläge gleichen einer gedämpften harmonischen Schwingung. Die Amplitude der einzelnen Schläge steigt jedoch nicht mit jedem Schlag an, sodass hier ein Maximum angenommen werden kann. Die gewonnenen Erkenntnisse über das Schwingverhalten bestätigen die aktuelle Maschinenauslegung sowohl hinsichtlich der ausgewählten

Schockfestigkeit der Motoren als auch die zu erwartende geringere Beschleunigung des Antriebsaufbaus im Vergleich zur Schabotte.

Bild 6-5 zeigt die im zweiten Szenario aufgezeichneten Beschleunigungswerte für alle drei Achsen und bestätigt ebenfalls die geringere Beschleunigung am Antriebsaufbau.

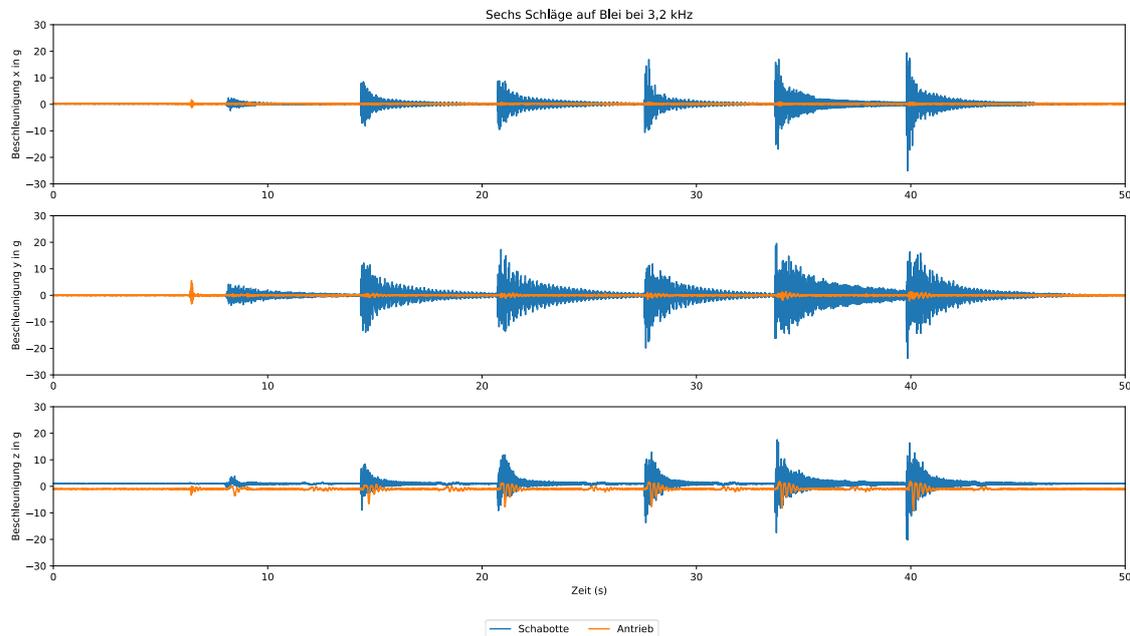


Bild 6-5: Beschleunigungsmessung an der Schabotte (blau) und des Antriebsaufbaus (orange) bei einer Abtastrate von 3,2 kHz (Szenario 2: sechs Schläge)

Zudem wird in der Untersuchung deutlich, dass sich der Maximalwert der Beschleunigung mit jedem aufeinanderfolgenden Hammerschlag erhöht. Dies ist auf die sich mit jedem Schlag erhöhende Kaltverfestigung und damit einhergehende Erhöhung des Umformwiderstandes zurückzuführen. Ferner ermöglichten die so aufgezeichneten Beschleunigungen das Schwingverhalten des Hammers weiter zu untersuchen und daraus Korrelationen sowie potentielle Produktverbesserungen abzuleiten. Eine Möglichkeit hierbei ist, dass die Auslegung der Schabotte hinsichtlich der real auftretenden Beschleunigungen optimiert wird.

6.1.2 Einbinden eines Oberdruckhammers an das Internet der Dinge

Problematik

Für die Nutzung von anlagenspezifischen Mess- und Systemdaten in der Generationenplanung reichen keine einzelnen Messversuche aus, bei denen lediglich CSV-Dateien generiert werden. Die Datensammlung muss dauerhaft und automatisiert, bzw. ohne manuellen Datentransfer erfolgen. Darüber hinaus müssen die gesammelten Daten dem Anlagenhersteller zugänglich sein. Eine mögliche Lösung stellt eine cloudbasierte IoT-Platt-

form dar. Dort können Daten automatisiert über das Internet gesammelt und dem Plattformnutzer bereitgestellt werden. In der aktuellen Produktgeneration ist allerdings noch keine hardware- sowie softwareseitige Infrastruktur vorhanden, um eine solche IoT-Anbindung umzusetzen. Darüber hinaus steht die bestehende IT-Infrastruktur in der Produktionshalle für derartige Vorhaben nicht zur Verfügung, da die Anbindung aus Gründen der Datensicherheit sowie nicht vorhandener Zugriffsrechte außerhalb des Firmennetzwerkes umzusetzen ist.

Zielsetzung

Als IoT-Plattform wurde die bereits vorgestellte Plattform „CONTACT Elements for IoT“ (vgl. Kapitel 5) der Firma CONTACT Software verwendet, welche maßgeblich bei der Implementierung unterstützte. Für die Anbindung der IoT-Plattform wurde eine Kommunikationsstrecke (IoT-Infrastruktur) von der Anlage auf Feldebene bis in die Cloud-Ebene umgesetzt. Auf Feldebene bestand daher die Zielsetzung, eine über die SPS hinausgehende Datenverarbeitung, -speicherung und -auswertung bis in die IoT-Plattform zu ermöglichen. Dazu war es erforderlich den Oberdruckhammer in das IoT einzubinden und die notwendige Infrastruktur hardwareseitig anzubauen und softwareseitig zu implementieren. Damit die Konnektivität zwischen der IoT-Plattform und der SPS hergestellt werden konnte, wurde ein Gateway unmittelbar an dem Hammer installiert. Die zur Weiterleitung der Daten erforderliche IT-Anbindung der Fertigungshalle (Standort des Hammers), war ein wesentlicher Teil der Zielsetzung. Auf Cloud-Ebene bestand die Zielsetzung darin einen digitalen Zwilling der Anlage in der IoT-Plattform anzulegen und diesen mit Daten aus der realen Anlage zu versorgen. Hierzu war ebenfalls eine Kommunikationsstrecke zwischen Edge Device und IoT-Plattform einzurichten. Ferner galt es, die aus den zum Einsatz kommenden Übertragungsprotokollen und Kommunikationstechnologien resultierenden Leistungscharakteristika, bspw. Echtzeitfähigkeit, Zykluszeit und Übertragungsgeschwindigkeiten, für die aufgebaute Kommunikationsstrecke zu bewerten.

Vorgehensweise

Damit die Kommunikationsstrecke abgebildet werden konnte, war es zunächst erforderlich die notwendigen Datenquellen am Schmiedehammer mit dem Konzept zur Sensornachrüstung (vgl. Abschnitt 3.2.3) zu erzeugen. Dazu wurde ein Use Case erarbeitet in welchem das Verhalten des Hydrauliksystems aufgezeichnet wird, um z. B. das Auftreten einer Leckage und dessen Ursache zu detektieren.

Zunächst wurde die zur Umsetzung des Use Case notwendige Sensorik am Hammer mechanisch und elektrisch integriert. Anschließend erfolgte die I/O-Link-Anbindung der ausgewählten Drucksensoren an die Anlagensteuerung über eine ET200sp Station (s. Bild 6-6). Somit waren sowohl die Messdaten der Sensoren als auch die Variablen und Zustände der Funktionsbausteine aus dem Anlagenprogramm in der Steuerung gebündelt. Von dort konnten sie mit dem integrierten OPC-UA-Server für einen Lesezugriff durch das Gateway bereitgestellt werden. Bei der vorhandenen CPU der Anlagensteuerung war

bereits ein OPC-UA-Server integriert, sodass dieser lediglich aktiviert und anhand einer einheitlichen IP-Adresse in das Netzwerk des Gateways integriert werden musste. Der Server bot die Möglichkeit einer genauen Definition der Datensätze, welche ausgelesen werden dürfen. Auf der Seite des Gateways war der Lesezugriff auf den Server eingerichtet. Hierzu war es notwendig, dass die variablen Adressen auf dem Server angefragt und vom Gateway ausgelesen werden konnten. Die Internetanbindung des Gateways ermöglichte die direkte Weiterleitung der ausgelesenen Rohdaten in eine Cloud-Anwendung sowie die lokale Vorverarbeitung im Vorfeld der Übertragung.



Bild 6-6: Schematische Darstellung der Datenübertragungsstecke auf Feldebene inkl. der jeweiligen Übertragungsprotokolle

Für die Kommunikation zwischen dem Gateway und der Cloud-Anwendung wurde das Kommunikationsprotokoll MQTT verwendet. Hierzu musste ein MQTT-Broker definiert werden, welcher als zentrale Instanz des Datentransfers fungierte und über das Internet erreichbar war. Dafür bot es sich an den Broker auf der Cloud Ebenen zu instanziiieren und sowohl das Gateway auf Feldebene als auch die IoT-Plattform auf Cloud Ebene als MQTT-Client zu betreiben. Ein Client kann im MQTT-Protokoll mit dem Broker kommunizieren und entweder Daten lesen (subscribe) oder bereitstellen (publish). Somit ergab sich die in Bild 6-7 dargestellte IoT-Infrastruktur, in welcher die Daten aus dem Oberdruckhammer zunächst auf Feldebene erzeugt und anschließend auf dem Gateway bereitgestellt werden.

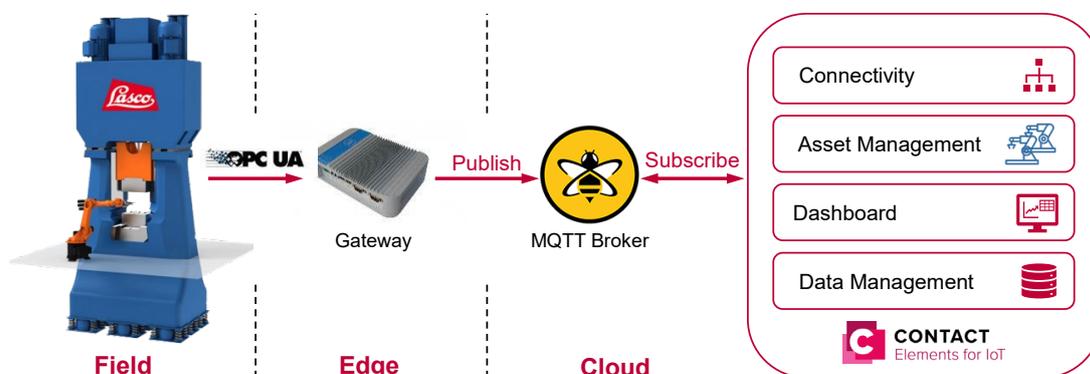


Bild 6-7: Schematische Darstellung der IoT-Architektur vom Produkt „Oberdruckhammer“ auf Feldebene bis zur IoT-Plattform auf der Cloud Ebene

Im Anschluss wurden die Daten über die MQTT-Verbindung in der IoT-Plattform "Contact Elements for IoT" produktspezifisch gespeichert und als Datensätze für Auswertungen zur Generationenplanung bereitgestellt. Zudem ermöglichte die IoT-Plattform eine Visualisierung der eingehenden Daten (s. Bild 6-8).

Resultate

Durch die Umsetzung der entwickelten Kommunikationsstrecke ist es gelungen, die für den definierten Anwendungsfall benötigten Daten in einer ausreichenden Granularität auf der IoT-Plattform bereitzustellen. Darüber hinaus wird ermöglicht, die am Oberdruckhammer erzeugten Datensätze dauerhaft zu übertragen, zu speichern und der Fa. LASCO online bereitzustellen. Das entstandene IoT-Netzwerk kann mit weiteren Anlagen ausgebaut werden, sodass zukünftig Daten von mehreren Anlagen in die Betriebsdaten-gestützte Produktplanung einfließen können. Die IoT-Plattform verfügt zur Visualisierung der eingehenden Telemetrie-Daten ein individuell anpassbares Dashboard (s. Bild 6-8), welches drei Hauptfenster besitzt.

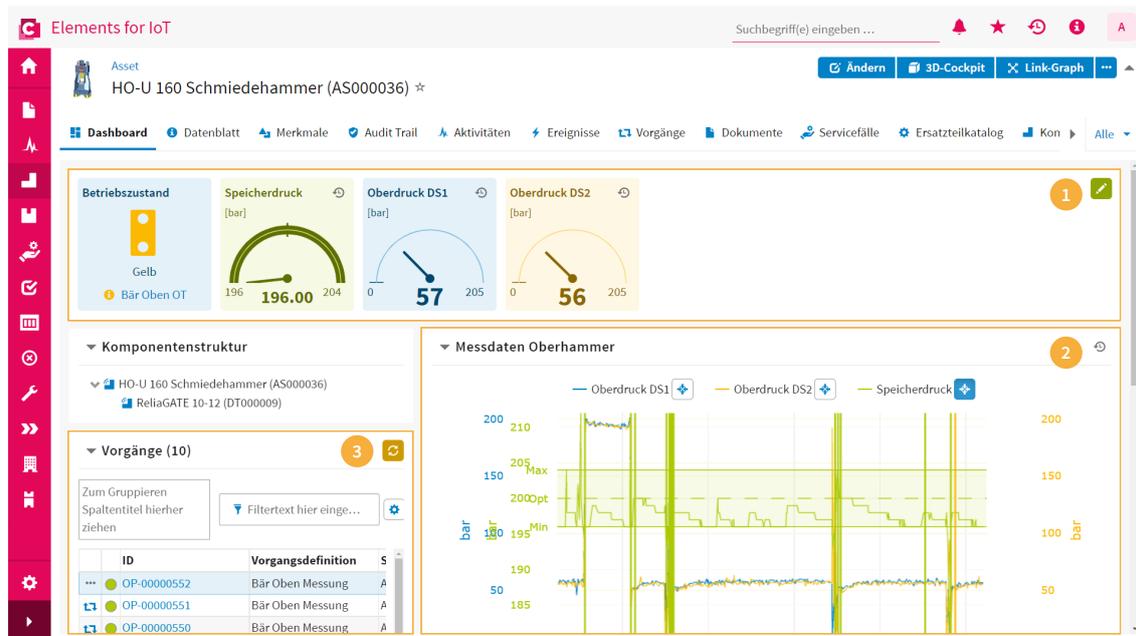


Bild 6-8: Ansicht IoT-Plattform

Im Bereich 1 werden der aktuelle Betriebszustand des Gateways und die Messwerte der drei Drucksensoren als absolute Zahlenwerte dargestellt. Bereich 2 visualisiert den Druckverlauf über einen ausgewählten Zeitraum. Für die Selektion von einem definierten Zustand der Anlage zugehörigen Daten, können Ereignisse (sog. „Vorgänge“) angelegt werden. Auslöser für einen Vorgang ist ein eingerichtetes Event, welches einen definierten Anlagenzustand abbildet und nach Verlassen des Zustands den Vorgang wieder beendet. Im Bereich 3 befindet sich eine Auflistung der aufgezeichneten Vorgänge. Jeder einzelne enthält einen Datensatz, welcher zum Selektieren der Daten genutzt werden kann. Die Weiterverarbeitung der Daten kann entweder über die Anzeige innerhalb der Vorgänge auf der IoT-Plattform oder lokal durch den Export im CSV-Format erfolgen.

Im Hinblick auf die Leistungscharakteristika der zum Einsatz gekommenen Übertragungsprotokolle wurde bereits erwähnt, dass die für das Beispiel „Erkennung einer Leckage“ notwendigen Daten in einer ausreichenden Granularität vorliegen. Hierbei ist allerdings zu erwähnen, dass Vorgänge betrachtet werden, welche mehrere Sekunden andauern und somit die Übertragungsgeschwindigkeit von 300 ms des OPC-UA-Servers ausreicht. Für die Bewertung des Hydrauliksystems und dessen Verhalten ist ein OPC-UA-Server nicht zu empfehlen, da hierzu eine deutlich höhere Übertragungsgeschwindigkeit (1 ms) notwendig ist.

6.2 Anwendungsbeispiel 2: Weidmüller Interface GmbH & Co. KG

Weidmüller steht für Lösungen für die Verbindung von Energie, Daten und Signalen. Daneben entwickelt Weidmüller auch Systeme für die kontaktlose Energieübertragung, Stromversorgung, I/O-Systeme, schwere Steckverbinder, Energiemessgeräte, Netzwerkinfrastruktur sowie Energiebussysteme. Ein wesentlicher Bestandteil des Produktportfolios sind kommunikationsfähige Elektronikkomponenten, die im Maschinen- und Anlagenbau zur Sammlung und Zusammenführung von technischen Betriebsdaten im Schaltschrank verbaut werden.

Unter dem Namen „**u-mation**“ bietet Weidmüller ein breit aufgestelltes Produktportfolio von Automatisierungslösungen an. Dieses reicht von der Speicherprogrammierbaren Steuerung (SPS) über Netzwerktechnik (Gateways, Router) bis zu Touch-Panels zur Visualisierung. Dazu zählen u. a. Feldbuskoppler, die Daten aus dem Feld (bspw. von Maschinen und Anlagen etc.) an Steuerungssysteme übergeben. Die „u-remote“-Feldbuskoppler (s. Bild 6-9) lassen sich durch ihren modularen Aufbau mit über 80 verschiedenen I/O-Modulen funktionell erweitern.



Bild 6-9: Feldbuskoppler "u-remote" von Weidmüller

6.2.1 Analyse von Log-Files am Beispiel eines Remote I/O-Systems

Problematik

Informationen zur Nutzung der u-remote-Feldbuskoppler werden vor allem in Logfiles dokumentiert und lokal auf den Geräten gespeichert. Sie beinhalten im Wesentlichen Informationen zum Aufbau des Moduls (verbaute Komponenten, Hard- und Firmware-Versionen), aber auch Betriebsdaten wie die CPU-Temperatur. Die systematische Erhebung der Logfiles ist somit eine Voraussetzung für die Untersuchung der Nutzung der u-remote-Feldbuskoppler; ihre heutige manuelle Erhebung gleichzeitig ein Hindernis. Zum Verständnis wird daher der heutige Erhebungsprozess beschrieben (s. Bild 6-10):



Bild 6-10: Heutiger Ablauf zur Erhebung von Nutzungsdaten via Logfile vom Kunden zur Entwicklung

- (1) Logfiles der u-remote werden in Problemfällen manuell an den 1st-Level-Support übermittelt. Dies geschieht üblicherweise per Mail.
- (2) Bei einfachen Lösungen wird diese durch den 1st-Level-Support zum Kunden zurückgespielt.
- (3) Bei komplexeren Problemen wird das Logfile an die Entwicklungsabteilung weitergegeben, um den Fehlerfall zu identifizieren.
- (4) Die Entwicklungsabteilung kann nach erfolgter Analyse eine Handlungsempfehlung oder ein Software-Update über den 1st-Level-Support an den Kunden zurückspielen.

Aus den beschriebenen Schritten ergab sich für Weidmüller die folgende Problematik:

- (1) Die Logfiles lagen dezentral in den Kopplern und mussten erst zusammengeführt werden.
- (2) Die Logfiles gingen in den E-Mails „verloren“ (d. h. Anhänge der E-Mails sind nicht mehr auffindbar).
- (3) Die Logfiles waren codiert und mussten zur Analyse erst dekodiert werden.
- (4) Einzelne Logfiles reichten nicht aus für eine Analyse der Feldeinsatz-Anforderungen.

Es fehlte eine zentrale, umfassende und auswertbare Erhebung der Nutzungsdaten zur Analyse.

Zielsetzung

Als Beitrag zur Lösung der Problematik sollten zwei Ziele erreicht werden: Einerseits sollte eine zentrale, kundenbezogene Speicherung von Logfiles zur Erhöhung der Datenquantität beitragen. Andererseits sollten die Daten zur leichteren Analyse mittels Dekodierung und Anreicherung aufbereitet werden. Dabei stellte das erste Ziel die Vorbedingung zur Verbesserung der Produkte auf Basis von tatsächlichen Nutzungsinformationen dar. Nur durch eine ausreichende Menge an Daten lassen sich valide Analysen über die Anforderungen der Anwendungsszenarien im Feldeinsatz erstellen. Das zweite Ziel stellte die Vereinfachung und Verbesserung der Daten-Analyse in den Fokus. Die Dekodierung erzeugt eine sowohl maschinell als auch menschenlesbare Form der Logfile-Daten. Sie reichern die statischen Produktdaten der u-remote (Digitales Abbild¹) um Informationen zum Praxiseinsatz (Digitaler Zwilling²) an. Hierzu zählen der physische Aufbau und die Modul-Reihenfolge der u-remote-Station, Hard- und Software-Versionen der Komponenten sowie die CPU-Temperatur. Aus dieser lässt sich die CPU-Auslastung ermitteln.

Vorgehensweise

Um die Ziele zu erreichen, wurde eine Systemstruktur zur automatischen Datenerhebung konzipiert und mit Hilfe von CONTACT Elements for IoT und einem RaspberryPi prototypisch implementiert.

Logfiles können von einem u-remote-System entweder manuell (via Weboberfläche) oder per http-Schnittstelle automatisch heruntergeladen werden. In der prototypischen Umsetzung erfolgte letzteres mit einer vorgeschalteten Gateway-Infrastruktur in Form eines RaspberryPi, die die Logfiles zyklisch abfragte und mittels MQTT-Protokolls an die IoT Plattform „CONTACT Elements for IoT“ übermittelte.

Diese Informationen standen dabei gleichzeitig dem Kunden (z. B. für das Status-Monitoring oder Predictive Maintenance) als auch Weidmüller zur Verfügung (s. Bild 6-11). Im „Elements for IoT“ wurden die ankommenden Daten dekodiert, visualisiert und gespeichert, sodass eine Analyse zu einem späteren Zeitpunkt möglich wurde.

¹ Im Weidmüller-Verständnis beschreibt der Begriff „Digitales Abbild“ alle statischen, während der Entwicklung entstandenen Produktinformationen, also ERP-Stammdaten, Materialien, 3D-Modelle etc.

² Der „Digitale Zwilling“ entsteht durch zusätzliche Nutzungsdaten (siehe oben) und bildet daher den tatsächlichen, aktuellen Zustand eines Produktes ab.

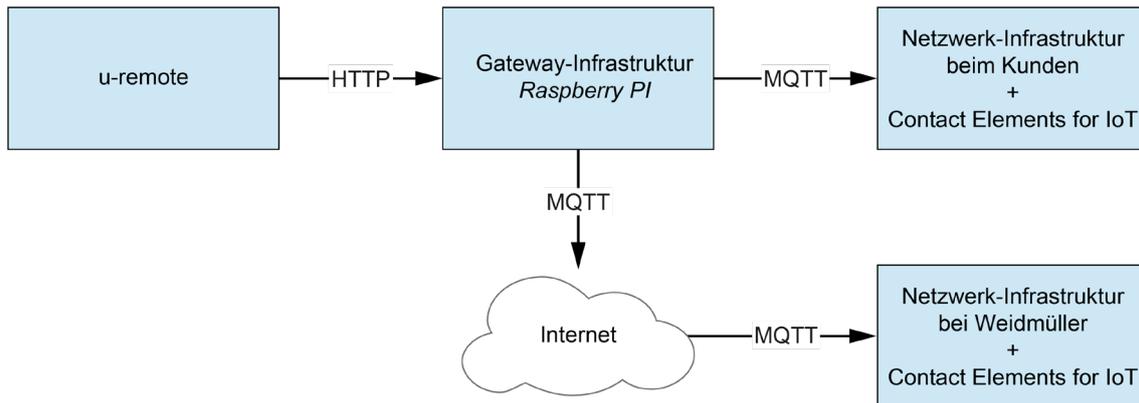


Bild 6-11: Prototypische Umsetzung zur Erhebung von Nutzungsdaten via u-remote-Logfiles (schematische Darstellung)

Resultate

Die technische Realisierung des Beitrags lässt sich im folgenden Bild verdeutlichen (s. Bild 6-12). Das u-remote-Webinterface (links) zeigt die Benutzeroberfläche der u-remote, auf der die gleichen Statusinformationen wie im Logfile zu finden sind. Über das auf dem vorgeschalteten Raspberry Pi laufende Python-Skript (Mitte) erfolgt die Dekodierung der Logfiles und die Übertragung der Daten an das CONTACT Elements for IoT (rechts).

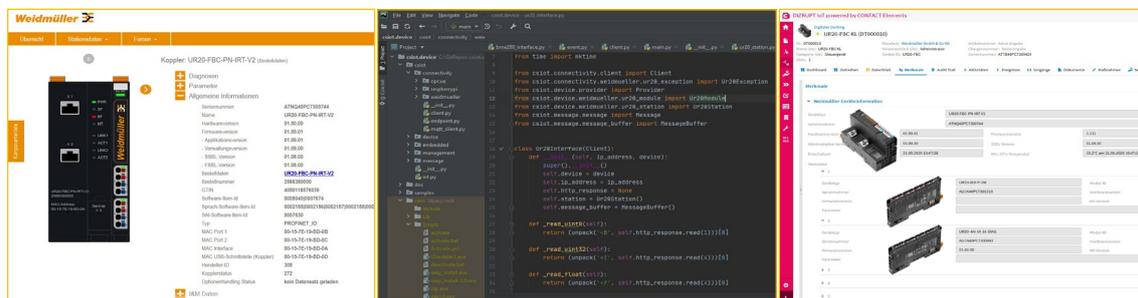


Bild 6-12: Technische Realisierung des Konzeptes zur Erhebung von Nutzungsdaten

Durch die kontinuierliche Abfrage der Logfiles kann ein ausreichender Datenbestand zu einem Digitalen Zwilling aufgebaut, verwaltet und visualisiert werden. Dashboards bieten dazu einen ersten Überblick über die vorhandenen Informationen und dienen als Navigator für Detailbetrachtungen (s. Bild 6-13).

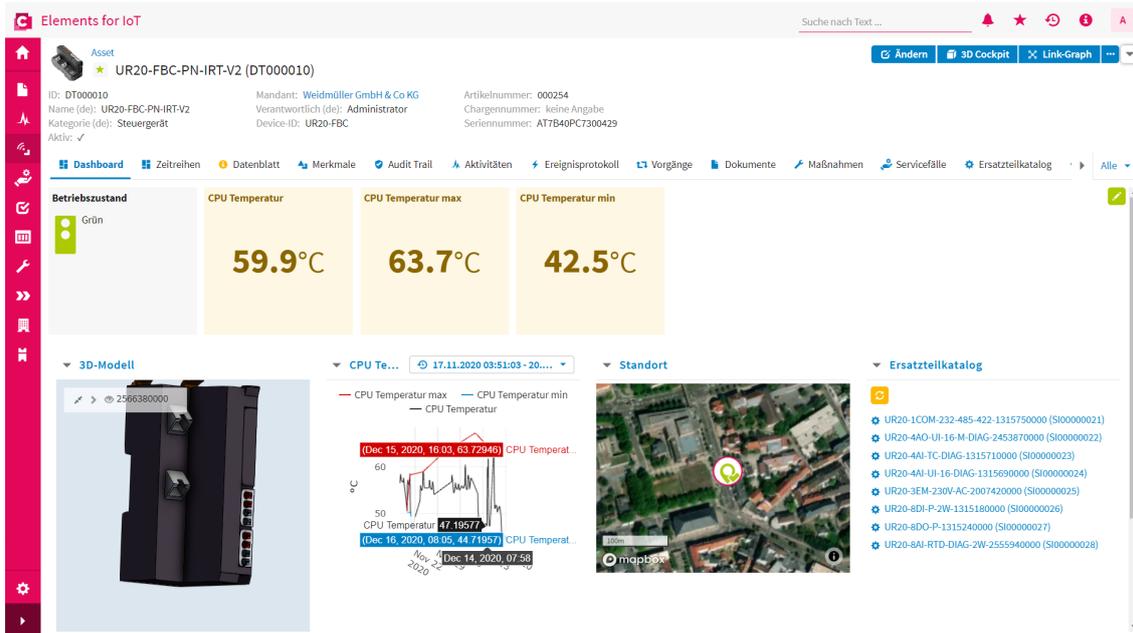


Bild 6-13: Dashboard des Digitalen Zwillinges im CONTACT Elements for IoT

6.2.2 Rückführung der Analyse-Erkenntnisse in das Requirements-Management-System

Problematik

Die Erkenntnisse aus Datenanalysen in der Generationenplanung sind nur von geringem Nutzen, solange die zu analysierenden Nutzungsdaten nicht automatisch erhoben und die Analyse-Ergebnisse nicht in den Requirements-Management-Prozess integriert werden. Der Aufwand der manuellen Erhebung war zu groß, um eine solide Datenbasis zu erhalten und eine Verwendung zu unsystematisch. Es bestand daher Bedarf an einer durchgängigen, automatisierten und integrierten Rückführung der Erkenntnisse in das Requirements-Management-System.

Zielsetzung

Das Ziel bestand darin, die Kette zwischen den Datenquellen (u-remotes verschiedener Kunden) und dem bestehenden Produktlebenszyklus-Management-System (PLM-System, bei Weidmüller: CONTACT CIM Database) zu schließen. Folgende Eigenschaften sollten dabei erfüllt werden:

- (1) Automatische Erfassung und Aufbereitung der u-remote-Daten.
- (2) Analyse der Daten mittels Algorithmen.
- (3) Überführung der Analyse-Ergebnisse in das PLM-System über eine Datenschnittstelle.
- (4) Ableitung des Digitalen Zwillinges aus den u-remote Produktinformationen im Produktlebenszyklus-Management (PLM).

Vorgehensweise

Zur Zielerreichung wurde erneut die Software „CONTACT Elements“ in ihren Ausprägungen „CIM Database“ als PLM-System und „Elements for IoT“ als IoT-System genutzt. Grundvoraussetzung für die Datendurchgängigkeit waren die Digitalen Zwillinge (Assets) der u-remotes in Elements for IoT. Diese wurden aus einem Digitalen Master (Asset-Type) instanziiert, welcher aus dem digitalen Produkt (Artikel) der u-remote in CIM Database abgeleitet wurde. Über die Kette Artikel zu Asset-Type und Asset-Type zu Asset war die Rückverfolgbarkeit zwischen den Informationen im PLM- und IoT-System gewährleistet, welche für die Übergabe von Erkenntnissen aus der Betriebsphase in die Generationenplanung und somit in das Requirements-Management-Modul in CIM Database von Bedeutung sind. Bild 6-14 visualisiert das Vorgehen zur Lösung der Problematik, welches im Folgenden kurz beschrieben wird.

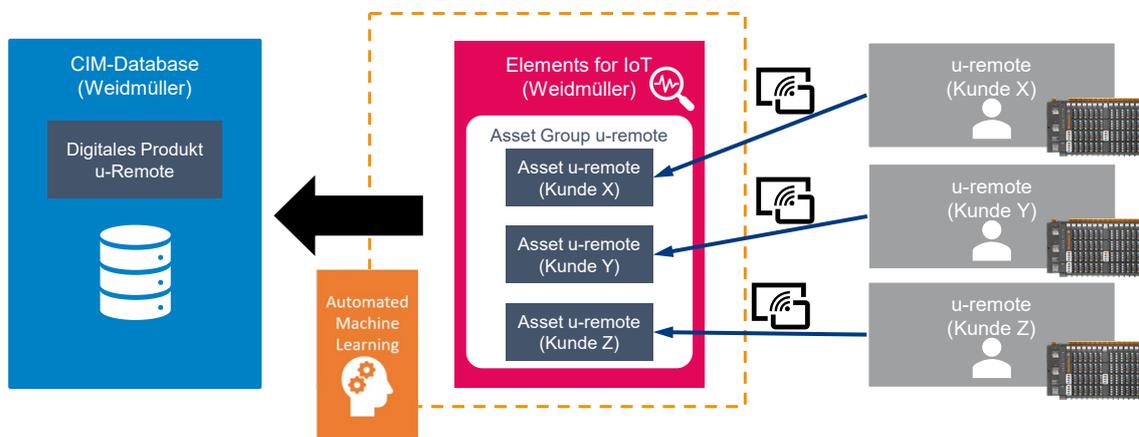


Bild 6-14: Prinzip-Lösung zur Rückführung von Analyse-Erkenntnissen in ein Requirements-Management-System

Jede u-remote eines Kunden sendet – nach dem in Abschnitt 6.2.1 beschriebenen Vorgehen – Informationen aus dem Betrieb an sein virtuelles Abbild (Asset) in CONTACT Elements for IoT. Dort werden die Informationen einerseits am Asset selbst verwertet, andererseits über eine nach festgelegten Regeln definierte Gruppe (Asset-Group) aggregiert. Die Asset-Group kann sich demnach auf eine bestimmte Produktausprägung der u-remote beziehen und alle Assets und deren Informationen beinhalten, welche aus dem Digitalen Master (Asset-Type) dieser Produktausprägung instanziiert wurden. Mithilfe von Analysewerkzeugen, wie beispielsweise dem Weidmüller Automated-Machine-Learning (AutoML)-Tool oder in CONTACT Elements for IoT integrierten Analyse-Mechanismen, können Erkenntnisse aus den Nutzungsdaten abgeleitet werden. Diese können einerseits wiederum an den Assets selbst verwertet werden, andererseits können die Erkenntnisse über die Schnittstelle zwischen IoT- und PLM-System und der bekannten Datenzugehörigkeit übertragen werden, um sie im Rahmen des Requirements-Management-Prozesses in der Generationenplanung zu verwerten.

Resultate

Im Beispiel der Weidmüller u-remote konnte eine durchgängige und integrierte Prozesskette entlang des Closed-Loop-Engineering-Ansatzes implementiert werden. Dabei lag der Fokus auf der Rückführung der Erkenntnisse aus dem Betrieb in die Requirements-Management-Prozesse (s. Bild 6-15).

The image shows a multi-panel screenshot of the 'Elements for IoT' and 'DIZRUPT PLM - CONTACT CIM Database' software. The top panel displays IoT monitoring data for 'UR20-FBC-PH-RT-V2 (D7000010)', showing three temperature readings: 59.9°C, 67.34°C, and 42.5°C. Below this is a 3D model of a component and a location map. The middle panel shows a 'Finding' for 'C00000003: Operating Temperatures' with properties like 'Type: Improvement suggestion' and 'Reported on: 11/11/2021 09:38:29'. A table of 'Finding Values' is shown with columns for Object, Index, Old Value, New Value, and Executed on. The bottom panel shows the 'Requirements' section for 'DizRuPt Generation Planning & Retro Fitting (S000000007/0)', with an editor for 'Operating temperatures' and a table of 'Acceptance Criteria'.

Object	Index	Old Value	New Value	Executed on	Execute
C00000003: Operating Temper...			67.34	11/11/2021 09:38:29	Administ

A. F.	Description ...	ID	Actual Value	Unit	Target R...
<input checked="" type="checkbox"/>	Maximum temperature	A000000005	67.34	°C	>=60
<input checked="" type="checkbox"/>	Minimum temperature	A000000006		°C	<=-20

Bild 6-15: Wichtige Zwischenergebnisse im Durchlauf des Closed-Loop-Engineering-Prozess mit Fokus auf der Rückführung der Erkenntnisse aus dem Betrieb der u-remote in die Requirements-Management-Prozesse

Hierfür wurden während der Produktuntersuchung im PLM-System zunächst Use Cases für eine Betriebsdaten-gestützte Generationenplanung der u-remote im Requirements-Modul in CIM Database definiert. Anschließend wurden diese um Akzeptanzkriterien ergänzt (s. Bild 6-15, unten), welche mit Erkenntnissen aus dem Betrieb bewertet werden. Dazu wurden an den verschiedenen u-remote-Assets Daten des dazugehörigen physischen Systems erfasst, verwaltet und verarbeitet (s. Bild 6-15, oben links). Auf Grundlage des Datenbestandes wurden Analysemodelle erzeugt und diese in das Vorgehen eingebunden.

Das Weidmüller AutoML-Tool analysierte Anomalie-Werte zur Laufzeit der Systeme und deren Telemetriedaten. Die Anomalie-Werte wurden ebenfalls in CONTACT

Elements for IoT an den Assets verwaltet und verwertet. Parallel dazu konnten über die in Elements for IoT vorhandene Automatisierung (s. Bild 6-15, oben rechts) und den darin eingebundenen Analyse-Modellen Erkenntnisse über den Einsatz der u-remote-Gruppe erzeugt und in ein entsprechendes Fachobjekt „Finding“ überführt werden. Mit Freigabe des Fachobjekts für die Synchronisation mit dem PLM-System wurde dieses in CIM Database überführt und mit dem entsprechenden digitalen Produkt der u-remote verlinkt. Durch die Verlinkung mit dem digitalen Produkt sind die gewonnenen Erkenntnisse ebenfalls im Kontext der zum Produkt gehörenden Requirements-Management-Prozesse verfügbar. Durch die Zuordnung der Erkenntnisse zu den entsprechenden Anforderungen bzw. Use Cases der Generationenplanung (s. Bild 6-15, unten) wurden die Werte des Finding-Objekts automatisiert in die Akzeptanzkriterien überführt und diese bewertet.

Somit wurde für den in der Problemstellung definierten Bedarf an einer durchgängigen, automatisierten und integrierten Rückführung der Erkenntnisse in das Requirements-Management-System eine Lösung geschaffen. Diese reduziert einerseits den (manuellen) Aufwand stark und erhöht andererseits die Verwertbarkeit von Betriebsdaten für die Generationenplanung bei Weidmüller signifikant.

6.3 Anwendungsbeispiel 3: Diebold Nixdorf Systems GmbH

Die Diebold Nixdorf Systems GmbH entwickelt und fertigt Automaten für Banken und den Handel an den Standorten Paderborn, Berlin und Ilmenau in Deutschland. Hierzu gehört auch die Entwicklung und Fertigung der mechatronischen Gewerke zur Geldverarbeitung einschließlich der Bereitstellung der unterschiedlichen Firm- und Middleware-Schichten. Darüber gelagert werden eigene Applikationen oder Fremdapplikationen adaptiert. Hinzu kommen weitere Softwarelösungen wie z. B. Lösungen für das Monitoring der Maschinen. Eines der Hauptfundamente des heutigen Geschäfts sind die in Paderborn entwickelten und gefertigten CINEO- und DN-Series-Systeme. DN Series ist die neuste Produktgeneration und CINEO die Vorgängergeneration. Alle Systeme dieser Serien ermöglichen über intern entwickelte Software-Lösungen eine Analyse der Geräte. Neben den Systemen der beiden genannten Serien sind noch einige Geldautomaten im Feld keine intelligenten technischen Systeme. Darüber hinaus sind diese Gerätetypen (von Kennzahlen bis hin zu Wartungsverträgen und Gerätezustand) weder in der Datenarchitektur abgebildet noch in dieser prinzipiell abbildbar.

Die DN-Series-Systeme bieten den Benutzern durch verschiedene Möglichkeiten der Personalisierung ein einzigartiges Erlebnis an der Schnittstelle zwischen physischer und digitaler Welt. Eine einheitliche Plattform, unterstützt von führender Software und innovativen Services, ermöglicht eine reibungslose Integration in die Ökosysteme von Banken. Darüber hinaus sorgt die Verbindung mit der „DN AllConnect Data Engine“ Service-Architektur mit weltweit bewährten, zuverlässigen Auszahl- und Recyclingmodulen für eine maximale Verfügbarkeit. Mehrschichtige, modular einsetzbare Sicherheitsfeatures schützen gegen traditionelle und zunehmend aufkommende physische Bedrohungen und

Cyberattacken. Bild 6-16 zeigt einen DN Series 200 Geldautomaten der neusten Produktgeneration.



Bild 6-16: DN Series 200 Geldautomat von Diebold Nixdorf

Ziel im Rahmen von DizRuPt war es, ein fundiertes Konzept zu entwickeln, das den gesamten Gerätebestand in eine vernetzte IoT-, PLM- und ERP-Systemlandschaft smart integriert. Diese Aufgabenstellung war aufgrund der inhomogenen Ausgangslage, sei es hinsichtlich der Systeme im Feld bis hin zur digitalen Infrastruktur, eine Chance und Herausforderung für die erfolgreiche Produktgenerationenplanung und Retrofitplanung zugleich. Im nachfolgenden Abschnitt 6.3.1 wird dazu dargestellt, wie bestehende Geräte im Kundenbestand durch Retrofitting für die Datenerhebung und -auswertung nachgerüstet werden können. Der darauffolgende Abschnitt 6.3.2 zeigt einen Ansatz zur Verbesserung der Wertschöpfung von Diebold Nixdorf durch Anwendung von Microservices und datenbasierten Geschäftsmodellen.

6.3.1 Datenakquise an einem Geldautomaten (geschlossenes System) durch eine intelligente Steckdose

Problematik

Die heutigen Generationen der Diebold Nixdorf Geldautomaten stellen hochinnovative und smarte Systeme dar. Darüber hinaus befinden sich jedoch unzählige Geldautomaten älterer Generationen im Feld, auf deren Daten nicht zurückgegriffen werden kann. Zu-

gleich fehlt es diesen Geräten an entsprechender Sensorik und Anbindung an Softwarelösungen, sodass diese Geräte als geschlossene Systeme betrachtet werden können. Dies führt dazu, dass Diebold Nixdorf und deren Servicepartner bei Problemen und Ausfällen zu spät Rückmeldung von ihren Kunden (Out-Of-Service) erhalten. Dadurch herrscht Unklarheit über den Zustand der Geldautomaten im Feld.

Zielsetzung

Im Rahmen des ersten Use Cases wurde daher das Ziel verfolgt, ein Konzept zu entwickeln und prototypisch umzusetzen, wie bestehende Geräte im Kundenbestand durch Retrofitting optimiert werden können. Da es sich bei den betrachteten Geldautomaten um geschlossene Systeme handelt, musste die benötigte Sensor-Nachrüstung außerhalb des Systems erfolgen und dabei dennoch Erkenntnisse über den inneren Zustand und die ausführenden Operationen des Geldautomaten liefern. Auf Basis der Erkenntnisse sollten dann Business-Anwendungen für Diebold Nixdorf als auch deren Servicepartner angesteuert werden können. Dazu müssen sowohl die erzeugten Daten als auch die daraus gewonnenen Erkenntnisse verwaltet und verarbeitet worden sein. Dies sollte in einer cloudbasierten IoT-Systemlandschaft erfolgen, welche sowohl einzelne Geräte als auch Flotten an Geldautomaten als Digitale Zwillinge verwalten kann. Zusätzlich sollte diese die Möglichkeit bieten die Geräte bzw. Flotten hinsichtlich der Kundenbasis und deren Datenhoheit zu differenzieren.

Vorgehensweise

Im Verbund zwischen Diebold Nixdorf, CONTACT Software und der TU Berlin wurde bei Diebold Nixdorf eine Teststellung aufgebaut, in welcher dem Geldautomaten eine intelligente Steckdose vorgeschaltet wurde. Dies hatte zum Ziel aus den gemessenen Strom- und Spannungsdaten Rückschlüsse auf die Nutzung, das Verhalten und den Zustand des Geldautomaten zu ziehen. Auf Basis generierter Trainingsdaten (für die Geräteoperationen Cash-In, Cash-Out, Reject und Retract) wurde durch die TU Berlin ein Classification-Service realisiert, dessen Analysemodell eingehende Strom- und Spannungsdaten auf die genannten ATM-Operationen mappt und als MQTT-Nachricht an den Digitalen Zwilling versendet. Die Umsetzung des Digitalen Zwillings des Geldautomaten erfolgte in der IoT-Plattform CONTACT Elements for IoT.

Dazu wurde für den Geldautomaten ein entsprechendes Asset erzeugt und die Erfassung der eingehenden MQTT-Nachrichten sowie die Verwaltung der sich darin befindenden Informationen definiert. Die Verarbeitung der eingehenden Daten erfolgte in drei Formen: 1) der Visualisierung der Informationen durch Dashboards, 2) der Berechnung von KPIs hinsichtlich der am Geldautomaten ausgeführten Operationen über definierte Zeiträume und 3) der automatischen Ausführung von Servicefällen auf Basis der vorherrschenden Datengrundlage. Bild 6-17 verdeutlicht die wesentliche Vorgehensweise beim Aufbau und Betrieb der Teststellung.

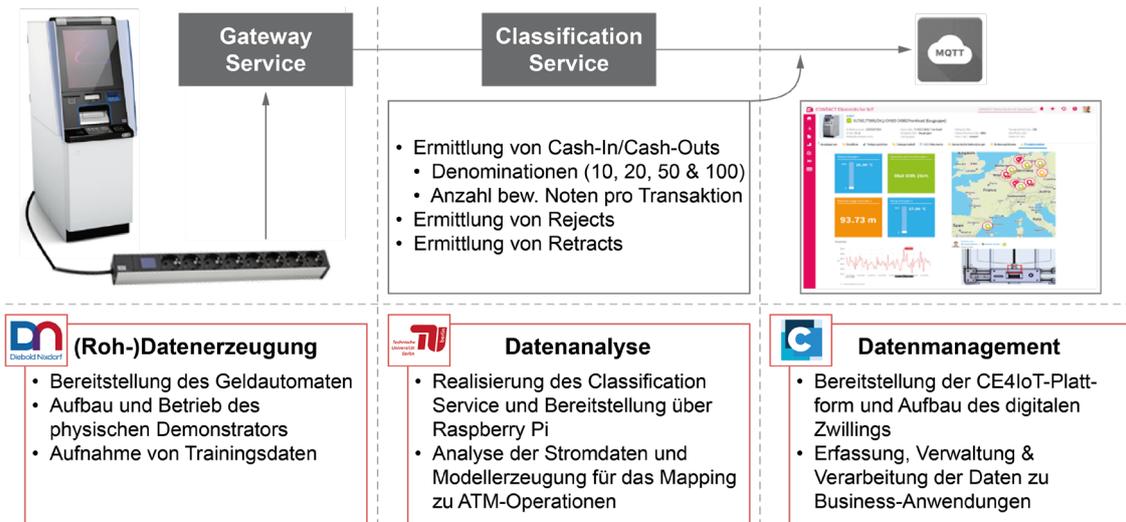


Bild 6-17: Konzept zum Aufbau der Teststellung

Resultate

Mit der Umsetzung des geplanten Vorgehens konnte der Beweis getätigt werden, dass durch die Anwendung von Datenanalysefähigkeiten und externer Sensorik in Form einer intelligenten Steckdose eine zutreffende Aussage bzgl. des Zustands und des Verhaltens der Geldautomaten getroffen werden kann. Es hat sich jedoch auch herausgestellt, dass für den Aufbau des Datenanalysemodells eine sehr hohe Datenrate und -granularität benötigt wird, um insbesondere zwischen den internen Abläufen im Geldautomaten unterscheiden zu können. Bild 6-18 zeigt einen Auszug aus den Messdaten.

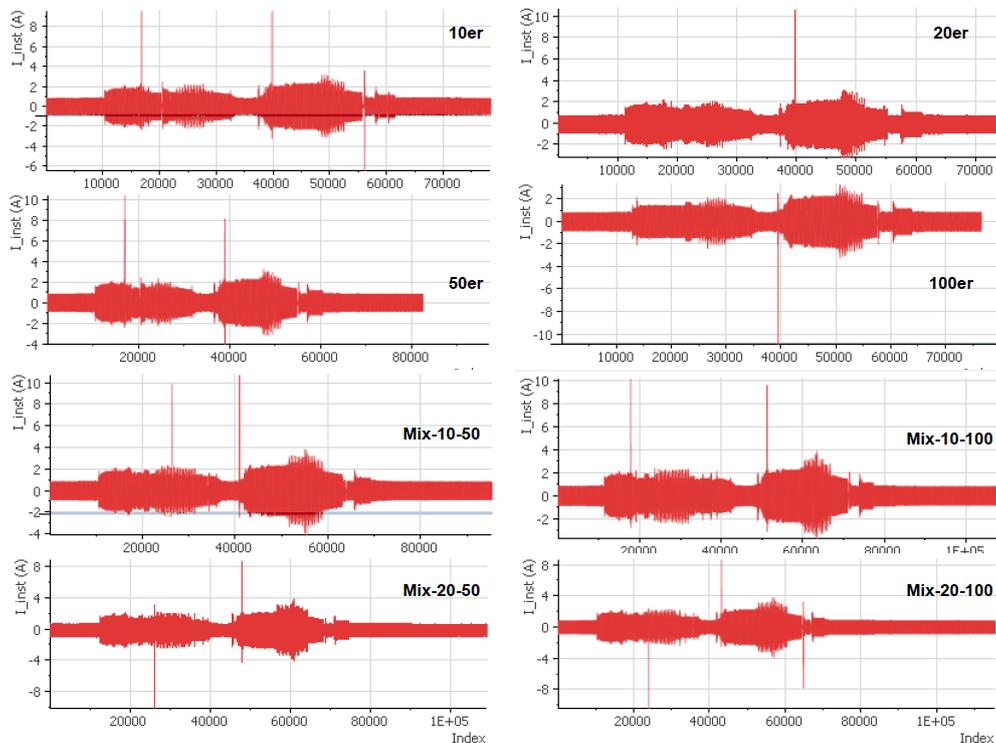


Bild 6-18: Messdaten zur Stromaufnahme bei verschiedenen Einzahlungen

Angesichts der hohen benötigten Datenrate wurde der Entschluss gefasst, dass die Verwaltung der entstehenden Datenmenge nicht gewinnbringend für die Verarbeitung und Ausführung der Business-Anwendungen im Digitalen Zwilling des IoT-Systems ist. Die Daten müssen vorverdichtet werden bzw. reichen für die Ergebnisse der Datenanalyse nicht aus. Folglich wurde ein Raspberry PI als Edge Device in die Datenstrecke integriert. Auf diesem werden die von der Steckdose kommenden Rohdaten über das von der TU Berlin entwickelte Analyse-Modell bewertet. Anschließend überträgt es das entsprechende Ergebnis als MQTT-Event an das Asset in CONTACT Elements for IoT. Bild 6-19 zeigt einen Auszug des Digitalen Zwillings.



Bild 6-19: Digitaler Zwilling des Geldautomaten in CONTACT Elements for IoT

6.3.2 Aufbau von Microservices und datenbasierten Geschäftsmodellen

Problematik

Obwohl bei Diebold Nixdorf bereits viele Daten erfasst und verarbeitet werden, wird das volle Potential der vorhandenen Daten nicht ausgenutzt. So kann beispielsweise durch die gezielte Datennutzung eine bessere Wertschöpfung für das Unternehmen erzielt werden. Zusätzlich zu den bereits vorhandenen, sehr wertvollen Vorteilen in der Produktplanung können die vorliegenden Daten dazu beitragen, weitere Anwendungen zu optimieren oder datenbasierte Geschäftsmodelle einzuführen.

Zielsetzung

Im zweiten Use Case wurde darauf aufbauend das Ziel der konzeptionellen und prototypischen Umsetzung von neuen Geschäftsmodellen verfolgt. Da aus dem ersten Use Case bereits Informationen hinsichtlich der Verwendung der Geldautomaten im Digitalen Zwilling verwaltet und verwertet wurden, sollten diese Daten für die Validierung eines ATM-as-a-Service-Geschäftsmodells wiederverwertet werden.

Dazu sollte im Zusammenspiel mit den Ergebnissen aus dem vom BMBF geförderten Forschungsprojekt IMPRESS eine Plattform für Vertrags-, Payment- und Rechnungsmangement für Smart Services aufgebaut werden. Die Vertragspositionen sollten dabei entweder über abgearbeitete Aufgaben oder auf Basis von Systemdaten aus der Nutzung der Geldautomaten beim Kunden bewertet werden. Dazu muss der Informationsaustausch zwischen der neu entwickelten Smart-Contract-Plattform sowie dem genutzten IoT-System sichergestellt werden.

Vorgehensweise

Da für den ersten Use Case bereits die offene Plattforntechnologie von CONTACT Software in Form der CONTACT-Elements-for-IoT-Plattform genutzt wurde, wurde für den Aufbau der Diebold Nixdorf Smart-Contract-Plattform ebenfalls auf diese Technologie zurückgegriffen. Im Rahmen der Umsetzung wurde das definierte Konzept des Closed-Loop-Engineering-Ansatzes erweitert. Bild 6-20 verdeutlicht das konzipierte Vorgehen.



Bild 6-20: Konzept zur Integration der Smart-Contract-Plattform in den Closed-Loop-Engineering-Ansatz

Aufbauend auf dem bestehenden Organisationsmanagement in CONTACT Elements wurde dieses um Zahlungsdaten bzw. Bankdaten erweitert. Parallel dazu wurde das neue Fachobjekt des Vertrags entwickelt. Dieses lässt sich, wie in Bild 6-21 dargestellt, zwischen zwei Organisationen als Kreditor und Debitor anlegen und besteht aus Vertragspositionen. Zur Abarbeitung solcher Positionen können diese mit vordefinierten Geschäftsobjekten verknüpft werden, um eine automatisierte Erfüllung der Vertragspositionen zu gewährleisten.

Im Falle des ATM-as-a-Service-Geschäftsmodells handelte es sich hierbei um die Zuordnung von Digitalen Zwillingen oder Flotten von Digitalen Zwillingen (dargestellt als Assets oder Asset-Gruppen in CONTACT Elements for IoT) sowie deren Funktionsumfang

zur Datenverarbeitung. Durch die vollständige Bewertung des Vertrags auf Basis seiner Vertragspositionen, wurde automatisiert ein ZUGFeRD-konformes Rechnungsdokument als PDF erzeugt, welches in einem parallel im System generierten Rechnungsobjekt hinterlegt wurde.

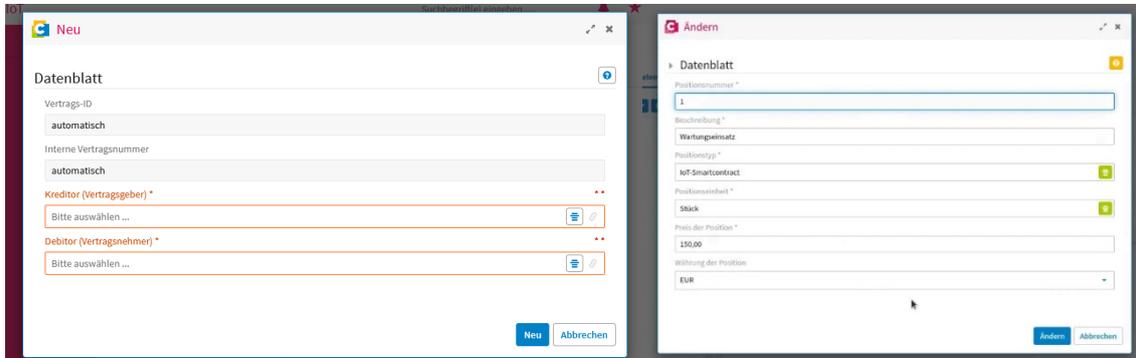


Bild 6-21: Anlegen eines Smart Contracts (links) und einer Vertragsposition (rechts)

Resultate

Die im Rahmen des zweiten Use Cases erzielten Ergebnisse verdeutlichen, dass die Potentiale von Nutzungsdaten vielfältig sind. Durch den veranlassten Retrofit des ersten Use Cases werden zusätzliche Daten generiert, die im digitalen Zwilling des Geldautomaten verwaltet und verarbeitet werden. Diese schaffen durch die Rückführung ins PLM-System einen Mehrwert für Produktplanung, indem sie für die Validierung angestrebter Produktverbesserungen neuer Produktgenerationen genutzt werden können. Darüber hinaus bilden sie die Grundlage für die Umsetzung datenbasierter Geschäftsmodelle. Das hier dargestellte Konzept zeigt eine erste prototypische Umsetzung für den Übergang vom klassischen Verkauf von Produkten hin zu einem Product-as-a-Service-Ansatz. Das Produkt wird vom Kunden nicht mehr gekauft, sondern dieser zahlt für die Nutzung der bereitgestellten Dienstleistung.

Im Rahmen des Demonstrators wurden zwei Möglichkeiten geschaffen: 1) am Digitalen Zwilling des Geldautomaten erkannte Servicefälle werden in Rechnung gestellt und 2) der Kunde zahlt für die individuelle Nutzung auf Basis der identifizierten Geräteoperationen (Cash-In, Cash-Out, Reject und Retract).

Bild 6-22 und Bild 6-23 verdeutlichen die Umsetzung der Diebold Nixdorf Smart-Contract-Plattform in CONTACT Elements und deren Integration zum Digitalen Zwilling des Geldautomaten.

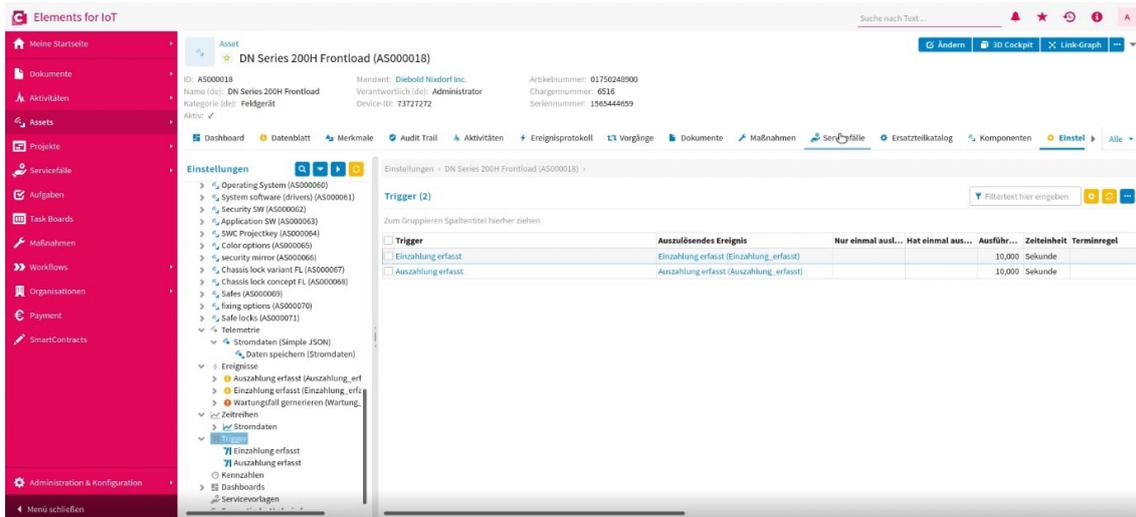


Bild 6-22: Asset-Einstellung zur Definition der Einzahlungs- und Auszahlungstrigger

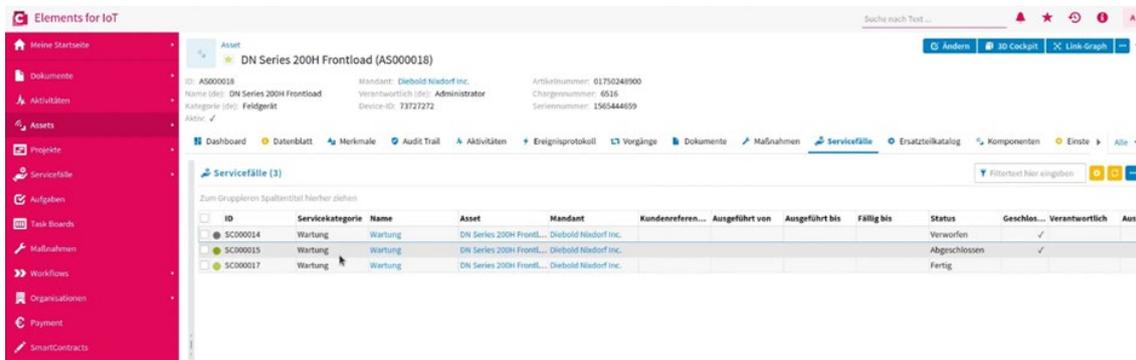


Bild 6-23: Übersicht der Wartungseinsätze für ein Asset

6.4 Anwendungsbeispiel 4: Westaflexwerk GmbH

Die Westaflexwerk GmbH (Westaflex) verfügt über weitreichende Kompetenzen in der Entwicklung von Lüftungsgeräten. Die Entwicklung der Lüftungsgeräte wird durch das Unternehmen vornehmlich in Eigenregie durchgeführt. Dabei werden alle technischen Disziplinen im Unternehmen, abgebildet – von der Mechanik über die Elektrotechnik bzw. Software bis hin zu den Produkttests. Die Lüftungsgeräte der neuesten Generation ermöglichen eine digitale Kommunikation über die vorhandene Infrastruktur. Bei älteren Geräten kann die benötigte Infrastruktur nicht vorausgesetzt werden. Auch können diese Geräte nicht oder nur in einem sehr begrenzten Maße eine digitale Infrastruktur nutzen. Der Endanwender hat auf diese Geräte über die digitale Infrastruktur keinen oder nur begrenzten Zugriff. Bild 6-24 zeigt das im Projekt betrachtete Lüftungsgerät.

Die Betriebsdaten der Lüftungsgeräte werden teilweise von den Geräten erfasst, aber nicht zur Auswertung an eine zentrale Stelle übersandt. Hier besteht erhebliches Potential für die Produktentwicklung, insbesondere durch Erkenntnisse über vorhandene und be-

nötigte Daten sowie Konzepte zur Nachrüstung von Sensorik für im Feld befindliche Systeme. Darauf aufbauend sind Aussagen über die Validität der bei der Produktentwicklung getroffenen Annahmen möglich. Diese neuen Erkenntnisse über den Produktnutzen können für die Betriebsdaten-gestützte Produktplanung genutzt werden.



Bild 6-24: Lüftungsgerät für die Wohnraumbelüftung

6.4.1 Nachrüstung von Beschleunigungssensoren am Gehäuse eines Lüftungsgeräts

Problematik

Das Produkt durchläuft im Lebenszyklus einen Lebensabschnitt, bei dem Gewinne aus den Verkäufen oder dem Betreiben nicht mehr möglich sind. Gründe hierfür stellen veränderte Kundenanforderungen, schrumpfende Märkte oder veraltete Technologien dar. In diesem Fall ist der Lebenszyklus des Produktes praktisch beendet: Das Produkt kann stillgelegt oder entsorgt werden. Alternativ besteht auch die Möglichkeit eines Relaunches in Form einer neuen Produkt- oder (System)generation.

Mit fortschreitender Digitalisierung fällt eine enorme Menge an Betriebsdaten an, welche zur Weiterverwendung zur Verfügung steht. Darauf aufbauend können neue Produktgenerationen geplant werden. Im vorliegenden Forschungsprojekt wurden daher Fragestellungen erarbeitet, die durch Analyse von Betriebsdaten beantwortet werden könnten. Die im Vorhaben betrachteten Fragestellungen bezogen sich auf den Verschleiß und den Ausfall von Lüftungsgeräten für die Wohnraumlüftung. Der Verschleiß und ein drohender Ausfall können über die Analyse von Vibrationen detektiert werden. Bislang fehlte es

hierfür an Sensoren im oder am Lüftungsgerät, die Schwingungen und Vibrationen aufnehmen können. Dies stellte die Problemstellung im Projekt dar.

Zielsetzung

Vor diesem Hintergrund war die Erarbeitung eines Messsystems zur Ermittlung des Geräteverschleißes das Ziel. Dieses sollte die aufgenommenen Messdaten mit typischen Verschleißmechanismen in Lüftungsanlagen korrelieren. Hierfür wurde eine Sensorik benötigt, die entweder die verursachten Schwingungen oder die Schallemissionen des Lüftungsgerätes detektiert. Schwingungen sind oftmals nicht vermeidbar. Sie sind auf die Konstruktion des Lüftungsgerätes zurückzuführen. Diese sind jedoch so konstruiert, dass sie mit minimaler Reibung arbeiten und Vibrationen durch den Massenausgleich und das Auswuchten vermeiden. Aus diesem Grund kann das Auftreten von Vibrationen ein Hinweis auf Probleme oder den Verschleiß des Lüftungsgerätes sein. Wenn die zugrunde liegenden Ursachen nicht beseitigt werden, können die unerwünschten Schwingungen selbst zusätzliche Schäden verursachen. Defekte Bauteile äußern sich bspw. durch eine kostenintensive Reparatur, einer geringeren Lebensdauer des Gesamtgeräts oder Produktionsausfällen. Gegenwärtig werden viele Sensoren zur Erfassung und Erkennung von Fehlern in rotierenden Maschinen eingesetzt, um ungeplante Ausfallzeiten zu vermeiden. Die Auswahl eines geeigneten Sensors stellt sicher, dass Fehler erkannt, diagnostiziert und vorhergesagt werden können. Ziel war dementsprechend die Auswahl eines geeigneten Sensors sowie das Erproben einer Nachrüstung am Gehäuse des Lüftungsgerätes.

Vorgehensweise

Zunächst wurden die für die Datenanalyse relevanten Einflussgrößen identifiziert und geeignete Sensoren zur Messung physikalischer Größen ausgewählt. Besondere Beachtung fanden die Umgebungsbedingungen hinsichtlich des Anwendungsgebietes: Ultraschallmikrofone und Vibrationssensoren können eine Zustandsänderung eines schwingenden Systems bereits Monate vor dem Ausfall detektieren. Damit eignen sich diese beiden Sensortypen am besten für die angestrebte Zustandsüberwachung.

Zur Messung und Sicherstellung der Vergleichbarkeit galt es bei der Auswahl eines **Ultraschallmikrofonmoduls** zu beachten, dass sich die Verstärkung nicht eigenständig ändert. Das "MAX4466" Modul, welches für die Testreihe zur Anwendung kam, verfügt über ein Kondensatormikrofon mit einem Frequenzgang von 20-20 kHz und einer einstellbaren Verstärkung von 25 x bis 125 x.

Bei dem **Vibrationssensor ADXL345** handelt es sich um einen 3-Achsen-Beschleunigungsmesser mit einer Messauflösung von 13 Bit bei ± 16 g. Die digitalen Ausgangsdaten werden als 16-Bit-Zweierkomplement formatiert und können entweder über eine digitale SPI- (3- oder 4-Draht) oder I2C-Schnittstelle mit einem preiswerten Mikrocontroller aufgenommen werden.

Der **Vibrationssensor ADXL35x** bietet eine sehr geringe Rauschleistung und verdrängt auch in **Condition-based maintenance**-Anwendungen (CBM) herkömmliche Beschleunigungssensoren. Neue Lösungen und Ansätze für CBM konvergieren zusammen mit IoT-Architekturen zu besseren Sensorik-, Speicher- und Analysesystemen. Die neuesten Beschleunigungssensoren von Analog-Devices ermöglichen vollständig integrierte Schwingungsüberwachungs- und Analysesysteme.

Für die Datenerfassung und Signalverarbeitung wurde ein Arduino UNO/DUE verwendet. Er bietet eine einfache und schnelle Programmierung und ihm ähnliche Mikrocontroller eignen sich auch für batteriebetriebene „low power“-Anwendungen. Die bereits erwähnte Frequenzanalyse enthält alle wichtigen Informationen des Signals und wird direkt auf dem Arduino durchgeführt, um die Datenmenge der Sensoren zu verringern und den seriellen Port nicht zu überfüllen. Für die Audiomessung (Messaufbau s. Bild 6-25 (1)) wurden zwei Positionen für das Mikrofon ausgewählt. Die erste Position befindet sich direkt im Luftstrom; während sich die zweite Position abseits des Luftstroms befindet. Für die Vibrationsmessungen wurden die Sensoren direkt am Ventilator montiert. Bild 6-25 (2) zeigt, dass die Vibrationsmessungen direkt am Ventilator erfolgten, wobei der Ventilator mit einer Unwucht versehen wurde.



Bild 6-25: Messaufbau: 1) Audiomessungen, 2) Vibrationsmessungen

Resultate

Die Messungen ohne Unwucht zeigten für die einzelnen Lüfterstufen ein vergleichbares Laufverhalten, wobei höhere Lüftungsstufen eine Offset-Kurve in den Frequenzen von 0 Hz bis 6000 Hz aufzeigten. Die niedrigeren Lüftungsstufen wiesen höhere Peaks an einigen „Resonanzfrequenzen“ auf. Bild 6-26 zeigt die Ergebnisse der einzelnen Lüfterstufen.

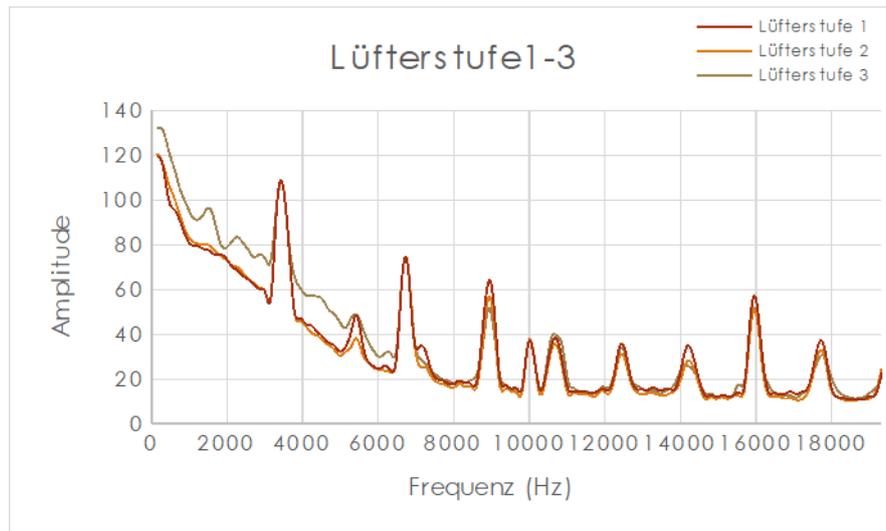


Bild 6-26: Lüfterstufen 1-3, Sensor MAX4466

Die Messung mit Unwucht zeigte, dass MEMS-Mikrofone (MAX4466) für den Einsatzfall nicht robust genug sind. Der ADXL 345 zeigte unter dem Einfluss der Vibrationen keine Reaktion, da er weder genau genug ist noch eine ausreichend geringe Rauschleistung aufweist. Für den ADXL 355 war die eingebrachte Unwucht messbar, sodass dieser für die geplante Anwendung geeignet war. Bild 6-27 zeigt den Vergleich der Lüfterstufe 100 % mit und ohne Unwucht ~ 30 sec – Sensor: ADXL345.

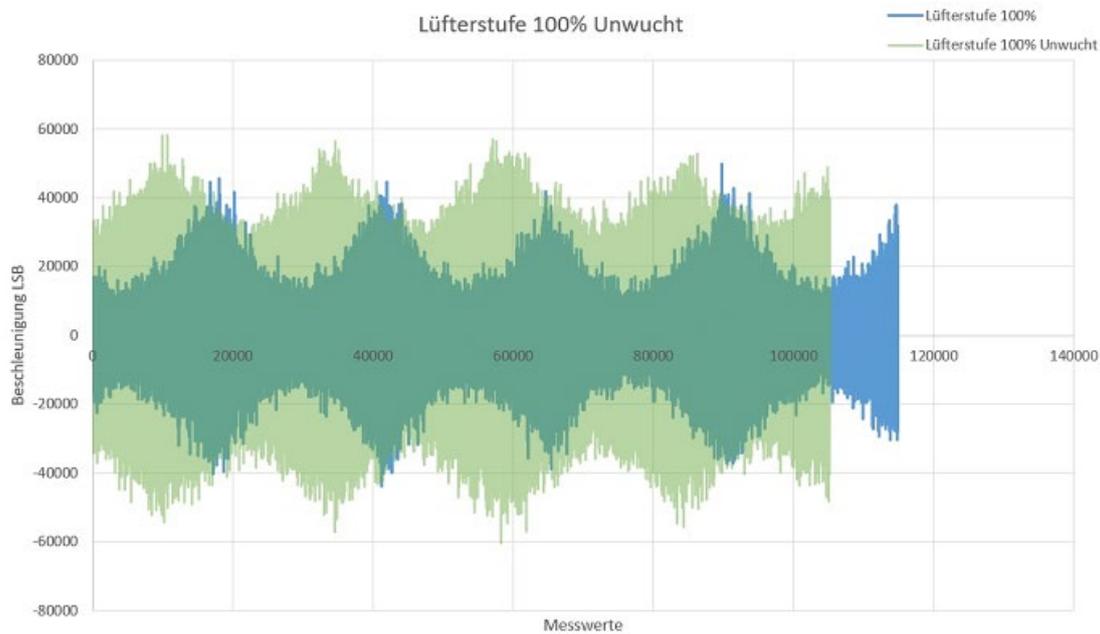


Bild 6-27: Vergleich Lüfterstufe 100 % mit und ohne Unwucht ~ 30 sec (ADXL345)

Ein weiteres Ergebnis der Untersuchung zeigte, dass die Unwucht am Ventilator die Schwingung in einem Bereich von ~ 50 Hz stark verstärkte, also etwa bei der Netzfrequenz. Mit dem ADXL 355 ist es nun möglich, Daten über den Verschleiß zu erfassen und damit Erkenntnisse über das Verschleißverhalten des Produkts zu generieren.

6.4.2 Analyse von Unwuchten in einem Lüftungsgerät

Problematik

Das Konzept der zustandsorientierten Instandhaltung ermöglicht eine Reduzierung von Maschinen-Stillstandszeiten und Kosten sowie die Optimierung von Betriebsabläufen. Dazu werden mit einem geeignetem Messsystem Veränderungen von Maschinenparametern wie Temperatur, Schallabstrahlung und Strukturschwingungen gemessen, um sie auf verschiedene Maschinenstörungen zurückzuführen. Über Kommunikationsverbindungen kann der Nutzer aktuell über den Zustand des Systems informiert werden. Obwohl die zustandsorientierte Instandhaltung mit einer Vielzahl von Sensoren durchgeführt werden kann, steht die Schwingungsanalyse im Mittelpunkt der Überwachung. Typische Fehler, die an rotierenden Maschinen auftreten sind bspw. Unwuchten, magnetisch induzierte Schwingungen und Lagerschäden. Diese Fehler können einzeln oder überlagernd auftreten, wodurch eine Unterscheidung erschwert wird. Um die analogen Beschleunigungssignale mit einem Computer oder Mikrocontroller verarbeiten zu können, müssen sie digitalisiert werden. In der Praxis geschieht dies durch die Entnahme von Signalwerten zu diskreten Zeitpunkten mit einem Abtast-Halteglied (Sample & Hold) und anschließender Quantisierung durch einen AD-Wandler.

Zielsetzung

Das Ziel der Untersuchung war die Erfassung und Analyse einer Unwucht an einem Radialventilator. Die Messwerte der Unwucht wurden mittels des ausgewählten Schwingungssensors erzeugt. Eine Unwucht, kann durch größere Partikel oder Staubablagerungen im Ventilator entstehen. Damit stellt die Unwucht ein Modell u. a. für die Verschmutzung dar. Ferner führen Lagerschäden zu Unwuchten. Eine frühzeitige Erkennung und Behebung dieser Störungen reduzieren die Betriebskosten erheblich.

Vorgehensweise

Bei der Messung von Schwingungen an Maschinen überlagern sich in der Regel mehrere periodische Schwingungen. Die resultierende Gesamtschwingung kann eine große gemeinsame Grundfrequenz ausweisen, die eine unmöglich große Blocklänge für die diskrete Fourier-Transformation erfordert. Zusätzlich treten zum Beispiel bei der Analog-Digital-Wandlung im Beschleunigungssensor statistische Störsignale auf, die sich nicht periodisch verhalten. Aus diesen Gründen muss davon ausgegangen werden, dass es bei der periodischen Fortsetzung von den aufzunehmenden Beschleunigungsdaten zu Sprungstellen kommt. Um den dadurch entstehenden Fehler im Frequenzbereich zu vermindern, wurden die Abtastwerte mit einer Fensterfunktion gewichtet.

Die Übertragungsfunktion der schwingenden Struktur hatte einen großen Einfluss auf das Messresultat. Jedoch variierte diese Übertragungsfunktion selbst bei Maschinen gleicher Bauart, aufgrund von unvermeidlichen Toleranzen oder anderen Montagebedingungen. Infolgedessen weist jede Maschine ihr eigenes individuelles Schwingungsspektrum auf, sodass ein Vergleich mit festgelegten Grenzwerten als nicht zielführend erschien. Der

Vergleich zwischen dem aktuellen Maschinenzustand und dem Ausgangszustand hingegen, ermöglicht Maschinenfehler zu identifizieren und zu korrelieren. Dabei wird das Spektrum der störfreien Maschine gemessen und mit dem aktuellen Spektrum an bestimmten Stellen verglichen.

Der Aufbau für die Messungen an dem zentralen Lüftungsgerät 300WAC ist in Bild 6-28 (1) dargestellt. Als Entscheidungskriterium für die Wahl der Messstelle wurde der Effektivwert der Beschleunigung für einen bestimmten Maschinenzustand gewählt. Die Platzierung des Sensors am Gehäuse direkt hinter dem Ventilator erzielte die höchsten Beschleunigungswerte und wurde als Folge dessen für die anschließende Spektralanalyse ausgewählt.

Bei den beiden verbauten Radialventilatoren R3G140-AW17-15 handelt es sich um bürstenlose Gleichstrommotoren mit elektronischer Kommutierung. Sie haben eine Nenn-drehzahl von 2750 min^{-1} und eine Nennleistung von 100 W. Für die beabsichtigte Erkennung einer Unwucht wurde am Lüfter 1 eine Unwuchtmasse von 1 g, 2 g oder 3 g am Lüfterrad montiert (s. Bild 6-28 (2)). Lüfter 2 arbeitete weiterhin im Normalbetrieb. Die Unwuchtmassen stellen ein Modell der Verschmutzung des Ventilators durch Staub oder ähnliche Partikel dar.

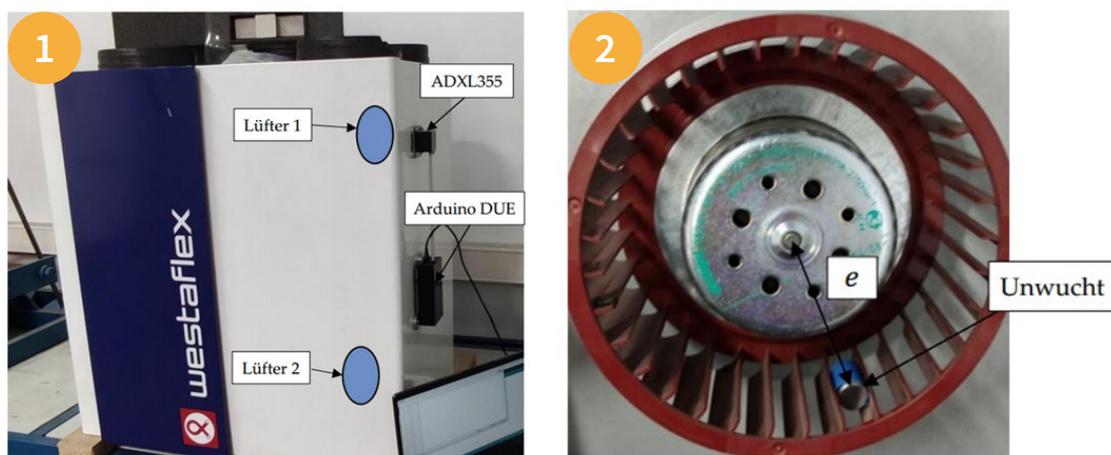


Bild 6-28: 1) Messaufbau am Lüftungsgerät, 2) Am Lüfter angebrachte Unwuchtmasse

Zum Erfassen und Speichern der Messdaten für die weitere Analyse wurde ein Arduino DUE verwendet. Dabei handelt es sich um einen Mikrocontroller, der auf der Cortex-M3-CPU von ARM basiert und eine Verarbeitungsbreite von 32-Bit besitzt. Aufgrund der hohen Taktrate von 84 MHz ist er für die Aufgabe der Messwerterfassung und Verarbeitung geeignet. Neben der erforderlichen SPI-Schnittstelle verfügt er unter anderem über 54 digitale Ein-/Ausgänge und 12 analoge Eingänge, die zur Messwerterfassung von weiteren Sensoren genutzt werden können. Das Arduino-Board hat eine Betriebsspannung von 3,3 V und konnte deshalb ohne Abwärtswandler mit dem „ADXL355“ kombiniert werden. Über die integrierte USB-Schnittstelle wurde eine serielle Verbindung mit einem Computer aufgebaut. Sie kam zum Einsatz, um Messwerte mit MATLAB zu visualisieren (s. Bild 6-29). Die integrierte Entwicklungsumgebung (IDE) vereinfacht Programmcodes

zu schreiben und auf das Arduino-DUE-Board zu laden. Durch die Verwendung von Bibliotheken konnten bereits lauffähige Unterprogramme, bspw. zur SPI-Kommunikation, einfach und schnell in den Programmcode implementiert werden.

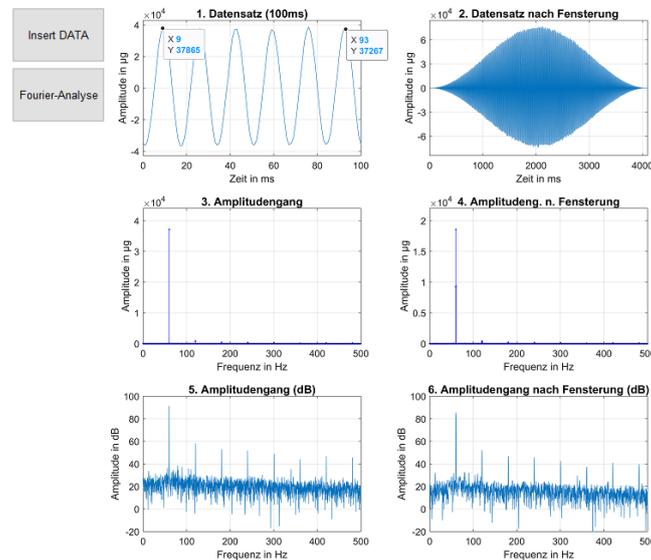


Bild 6-29: Beispiel einer MATLAB-Oberfläche zur Messwerterfassung und -analyse

Eine Anforderung an das zu entwickelnde Messsystem war die vielseitige Einsatzmöglichkeit. Um die elektrischen Kontakte des Arduino und des Sensors vor mechanischer Beschädigung zu schützen, wurde für den Prototypen ein 3D-gedrucktes Gehäuse konstruiert (s. Bild 6-30). Es besteht aus dem Kunststoff Acrylnitril-Butadien-Styrol (ABS). Dabei handelt es sich um einen Thermoplast, der sich durch eine geringe Materialdichte von $1,03 \text{ g/cm}^3$ auszeichnet und elektrisch isolierend ist.



Bild 6-30: Messsystem Arduino DUE + ADXL355

Der Sensor wurde zusammen mit dem Entwicklerboard EVAL-ADXL355Z wie in Bild 6-31 verwendet. Es ermöglicht eine einfache Kontaktierung der Sensor-Pins und verfügt über mehrere Keramikkondensatoren zur Entkoppelung der Stromversorgung. Die geringen Abmessungen von (20 mm x 20 mm x 1 mm) verleihen der Platine eine hohe Steifigkeit, die die Auswirkungen auf das zu überwachende System minimierte.



Bild 6-31: Entwicklerboard EVAL-ADXL355Z

Die in der Messkampagne aufgenommenen Messdaten wurden für eine Analyse mittels eines Programms zum Maschinellen Lernen (ML) aufbereitet. Nach dem erfolgreichen Training der ML-Software, konnte aus den Trainingsergebnissen eine Softwareapplikation zur Ermittlung der Laufruhe bzw. Unwucht als Testprogramm programmiert werden. Die Einsatzfähigkeit des Testprogramms konnte am Lüftungsgerät verifiziert werden.

Resultate

Für die Messwertanalyse wurden die Sensordaten der Z-Achse des 3-achsigen Sensors ausgewählt und einer Spektralanalyse unterzogen, da hier die stärkste Reaktion auf die Unwuchtkraft auftrat. Dazu wurde eine Abtastfrequenz von $f_s = 4000$ Hz, eine Bandbreite von $B = 1000$ Hz und eine Blocklänge $N = 4096$ gewählt, um gleichzeitig die gesamte Bandbreite des Sensors auszunutzen und dennoch eine gute Frequenzauflösung zu erreichen.

Aus Bild 6-32 lässt sich ableiten, dass das Gehäuse mit einer Grundfrequenz von $f_0 = 40$ Hz schwingt. Dies entspricht der Schwingungsantwort für eine Unwuchterregung mit einer Drehzahl von $n = 2400 \text{ min}^{-1}$ und deckt sich mit den Tachodaten für den Lüfter 1 der Lüftungsanlage.

Die Von-Hann-Fensterfunktion vermindert das „Auslaufen“ der FFT-Linien an Punkt 2 im Vergleich zum Punkt 1 ohne Fensterfunktion. Dadurch sind die harmonischen Frequenzen in Bild 6-32 (6. Amplitudengang nach Fensterung) deutlicher zu erkennen als in Bild 6-32 (5. Amplitudengang) und ist für den Vergleich zwischen zwei Maschinenzuständen besser geeignet.

Bild 6-33 stellt die Amplitudengänge für die drei verschiedenen Unwuchtmassen dar. Es ist deutlich zu erkennen, dass die Amplituden zunehmen, wenn die Unwuchtmasse erhöht wird.

Anhand der Messergebnisse wird deutlich, dass die Laufruhe des Lüftungsgerätes bzw. der Ventilatoren mit dem ausgewählten Sensor erfassbar ist. Steigende Belastungen mit Fremdpartikeln wie Staub können nach und nach zu ungewünschten Schwingungen führen, die die Lebensdauer bzw. Funktionärstätigkeit der Ventilatoren beeinträchtigen.

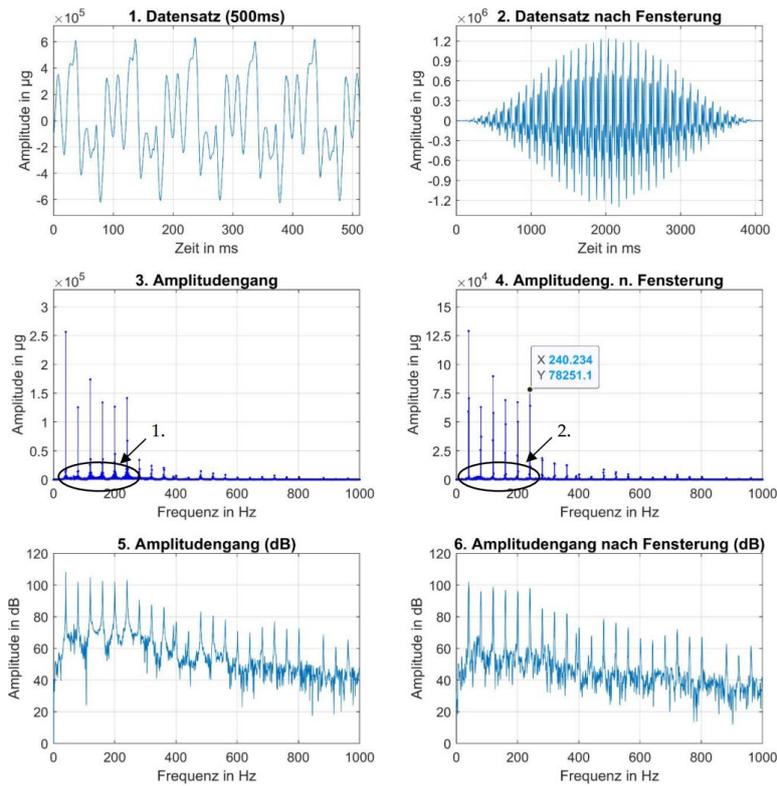


Bild 6-32: Spektralanalyse ohne Unwuchtmassen

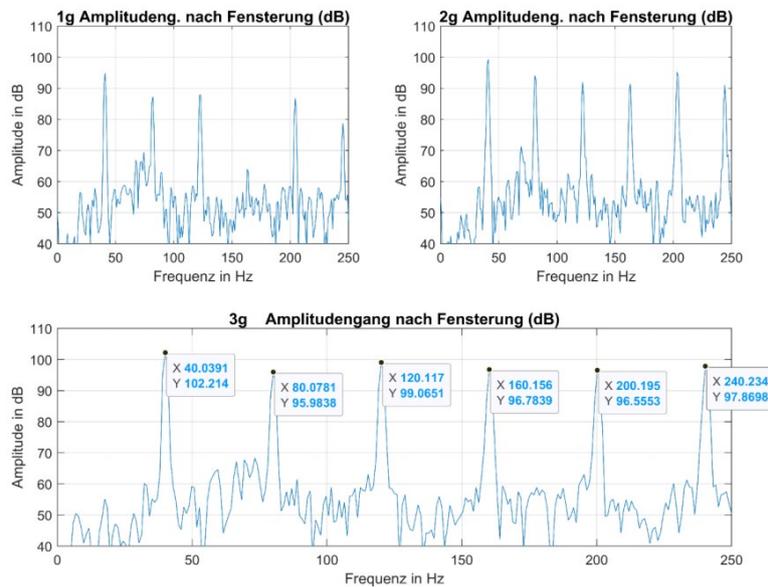


Bild 6-33: Spektralanalyse mit verschiedenen Unwuchtmassen

Literatur zu Kapitel 6

[Her13] Herbertz, R.; Hermanns, H.; Labs R.: Massivumformung kurz und bündig, Industrieverband Massivumformung e.V., Hagen, 2013, S. 89, ISBN: 978-3-928726-32-0

7 Tipps für den Transfer in die Praxis

Maurice Meyer, Melina Panzner, Ingrid Wiederkehr, Timm Fichtler

Im Rahmen des Konsortialforschungsprojekts DizRuPt konnten wir über dreieinhalb Jahre mit drei Forschungspartnern, einem Befähiger- und vier Anwenderunternehmen an der Betriebsdaten-gestützten Produktplanung forschen. Dabei stellten wir fest, dass die langfristige Implementierung der im Projekt entwickelten Prozesse, Methoden, Modelle und IT-Werkzeuge (vgl. Kapitel 3, 4 und 5) in den Anwenderunternehmen alles andere als trivial ist. Als Konsortium begegneten wir gemeinsam vielfältigen Herausforderungen, die der Vision der Betriebsdaten-gestützten Produktplanung im Weg standen und ihre Realisierung erschwerten. Um anderen Unternehmen einige dieser Stolpersteine zu ersparen und die Implementierung unserer Ergebnisse zu unterstützen, präsentieren wir daher nachfolgend sechs Tipps für den Transfer der Betriebsdaten-gestützten Produktplanung in die Praxis:

- (1) **Führungskräfte frühzeitig aktiv einbinden:** In den Pilotprojekten der Anwenderunternehmen konnten wir immer wieder beobachten, dass die Umsetzung der Betriebsdaten-gestützten Produktplanung in Folge dringender Aufgaben aus dem Tagesgeschäft verzögert wurde. Auch die Erteilung notwendiger Freigaben (z. B. von Ports durch die IT) gestaltete sich zum Teil sehr schwierig und langwierig. Durch die aktive Einbindung von Führungskräften gelang es, zahlreiche dieser Hürden schneller und mit einer größeren Überzeugung zu überspringen. Daher empfehlen wir, Führungskräfte (z. B. aus der Geschäftsführung und der Entwicklungsleitung) möglichst frühzeitig aktiv in das Vorhaben einzubinden.
- (2) **Partner für das Datenhandling und die Datenanalyse einbinden:** Gerade in Unternehmen des oftmals eher klassisch geprägten produzierenden Gewerbes stehen Themenfelder wie Big Data, Cloud Computing und Data Analytics noch immer am Anfang. Und wie allgemein bekannt ist, ist aller Anfang schwer. Auch wir haben im Projekt erlebt, dass Themen wie das Datenhandling und die Datenanalyse unerfahrene Unternehmen vor große Herausforderungen stellen können. Ein Erfolgsfaktor in unserem Projekt war dabei, dass wir mit den Forschungspartnern und dem Befähigerunternehmen auch die Kompetenzen an Bord hatten, die wir in diesen Bereichen benötigten. Wir erachten es daher als essentiell, kompetente Partner für das Datenhandling und die Datenanalyse einzubinden.
- (3) **Vertrauensvolle Kundenbeziehungen nutzen:** Die Grundvoraussetzung für die Betriebsdaten-gestützte Produktplanung ist das Vorhandensein von Betriebsdaten. Doch auch wenn die Produkte grundsätzlich große Mengen an Betriebsdaten generieren, heißt dies noch lange nicht, dass die Betriebsdaten dem Hersteller auch zur Analyse zur Verfügung stehen. Neben den allgemeinen Vorschlägen zur Incentivierung der Kunden für die Datenbereitstellung (vgl. Abschnitt 4.4) ist es aus unserer Sicht wichtig zu betonen, dass zu Beginn vor allem langjährige Kun-

den angesprochen werden sollten, zu denen ein ausgeprägtes Vertrauensverhältnis besteht. Auf der Grundlage gemeinsamer früherer Erfolge lässt sich einfacher und offener über die Rückführung und Analyse von Betriebsdaten sprechen als es mit eher neuen Kunden der Fall wäre. Deshalb raten wir zur Nutzung vertrauensvoller Kundenbeziehungen.

- (4) **Interne Vermarktungskampagne starten:** Die Analyse und Verwertung von Betriebsdaten in der strategischen Produktplanung erfordert zahlreiche organisatorische Veränderungen, die sich in neuen Prozessen, Methoden, Rollen und Aufbaustrukturen zeigen (vgl. Kapitel 3 und 4). Wie wir im Rahmen unserer Interviewstudie herausfanden, stoßen derartige Veränderungen in zahlreichen produzierenden Unternehmen auf Widerstände in der Belegschaft (vgl. Abschnitt 2.3). Damit die Betriebsdaten-gestützte Produktplanung ihr Potential entfalten kann, müssen die Mitarbeiter an ihrer heutigen Position abgeholt und die Mehrwerte dieses neuen Themas verständlich artikuliert werden. Anschaulich gesprochen bedarf es also einer internen Marketingkampagne, um die Mitarbeiter für dieses komplexe, aber innovative Thema zu gewinnen.
- (5) **Momentum nutzen und IT-Infrastruktur modernisieren:** Während des Projektverlaufs konnten wir in zahlreichen Situationen und in allen Anwenderunternehmen beobachten, dass die angeregten Veränderungen allerlei Handlungsbedarfe an der IT-Infrastruktur offenlegten. Zum Beispiel war die Datendurchgängigkeit in einem Unternehmen aufgrund zahlreicher Datensilos nicht gewährleistet. In anderen Unternehmen fehlten die technischen Möglichkeiten zur automatischen Rückführung der Betriebsdaten. Anstatt nur schnelle Lösungen für das akute Problem zu suchen, bietet es sich an, den Stand der IT-Infrastruktur etwas grundsätzlicher zu erörtern und ein attraktives Zielbild zu entwickeln. Wir empfehlen daher, das durch die Betriebsdaten-gestützte Produktplanung entstandene Momentum zu nutzen und eine umfassende Modernisierung der IT-Infrastruktur in Betracht zu ziehen.
- (6) **Mutig vorgehen und ausprobieren:** Trotz all der Methoden, Erfahrung und Tipps, die wir in diesem Buch auch mit interessierten Unternehmen teilen, bleibt die Analyse und Verwertung von Betriebsdaten in der strategischen Produktplanung ein komplexes Thema. Im Projekt haben wir dabei jedoch die Erfahrung gemacht, dass eine Übersystematisierung während des Themenangangs nicht hilfreich ist, sondern in der Praxis eher Verwirrung stiftet. Es kommt stattdessen darauf an, das Thema praxisnah anzugehen und zunächst kleine, aber relevante Pilotprojekte zu verfolgen, um eigene Erfahrungen zu machen und Lerneffekte zu erzielen. Außerdem sollte zunächst das grundsätzliche Vorgehen verinnerlicht werden, bevor die inhaltliche Komplexität überhandnimmt. Abschließend gehört auch etwas Mut dazu, das Thema im eigenen Unternehmen voranzutreiben und immer wieder Neues auszuprobieren.

8 Resümee und Ausblick

Roman Dumitrescu, Christian Koldewey, Maurice Meyer

Die strategische Produktplanung sieht sich seit jeher einem Dilemma ausgesetzt: Auf der einen Seite besitzt sie große Gestaltungsfreiheiten und entscheidet damit maßgeblich über den Erfolg neuer Produkte. Auf der anderen Seite fehlen ihr jedoch stets belastbare Daten und Informationen, um auswirkungsstarke produktstrategische Entscheidungen auf einem solideren Fundament als Vermutungen und Spekulationen zu treffen. Im Zuge der Digitalisierung stehen jedoch vermehrt umfangreiche Betriebsdaten cyber-physischer Systeme (CPS) zur Verfügung, die mit leistungsstarken Data-Analytics-Lösungen nach Mustern und Auffälligkeiten untersucht werden können. Die systematische Betriebsdaten-Analyse in der strategischen Produktplanung verspricht für die Hersteller der CPS wertvolle Erkenntnisse über ihre Produkte, Kunden und Nutzer. Jedoch stellt sich die Integration von Betriebsdaten-Analysen im Rahmen der strategischen Produktplanung für produzierende Unternehmen als Herausforderung dar. Vor diesem Hintergrund stellt sich die Frage: Wie können produzierende Unternehmen die Potentiale von Betriebsdaten und Data Analytics zur faktenbasierten Planung zukünftiger Produktgenerationen erschließen?

Das vorliegende Buch stellt ein Instrumentarium vor, das diese Frage praxisnah aufgreift und beantwortet. Erarbeitet wurde es im Rahmen des **Konsortialforschungsprojekts DizRuPt – Datengestützte Produktplanung**, das von Januar 2019 bis Juni 2022 vom Bundesministerium für Bildung und Forschung gefördert wurde. Das Konsortium setzte sich aus drei Forschungsinstitutionen (Heinz Nixdorf Institut der Universität Paderborn, Technische Universität Berlin und Fachhochschule Südwestfalen), einem Befähigerunternehmen (CONTACT Software GmbH) und vier Anwenderunternehmen (LASCO Umformtechnik GmbH, Weidmüller Interface GmbH & Co. KG, Diebold Nixdorf Systems GmbH und Westaflexwerk GmbH) zusammen.

Kern des vorliegenden Buchs ist der Referenzprozess für die Betriebsdaten-gestützte Produktplanung, der in **Kapitel 3** vorgestellt wird. Dieser besteht aus den vier Hauptprozessen Planung, Vorbereitung, Durchführung und Verwertung von Betriebsdaten-Analysen in der strategischen Produktplanung, die jeweils wiederum aus vier Phasen bestehen. In jeder Phase werden konkrete Methoden zur Durchführung der jeweiligen Aufgaben vorgeschlagen. Damit zeigt der Referenzprozess ausführlich, wie Betriebsdaten-Analysen gezielt im Rahmen der strategischen Produktplanung eingesetzt werden können.

Aufbauend auf dem Referenzprozess beschreibt **Kapitel 4** die effiziente Umsetzung der Betriebsdaten-gestützten Produktplanung im Unternehmen. Dabei werden wesentliche Rollen und zugehörige Kompetenzprofile vorgestellt, die zur effizienten und systematischen Durchführung der Betriebsdaten-gestützten Produktplanung beitragen. Darüber

hinaus werden Vorschläge für die organisatorische Verortung von Data-Analytics-Ressourcen in produzierenden Unternehmen unterbreitet. Abschließend werden Maßnahmen zur Incentivierung der Kunden für die Bereitstellung von Betriebsdaten präsentiert.

Die IT-seitige Umsetzung der Betriebsdaten-gestützten Produktplanung wird in **Kapitel 5** beschrieben. Dabei wird zunächst die werkzeugseitige Unterstützung des Referenzprozesses vorgestellt. Anschließend wird ausführlich darauf eingegangen, wie die Datendurchgängigkeit entlang des Closed-Loop-Engineering-Ansatzes erzielt werden kann.

In **Kapitel 6** werden ausgewählte Einblicke in die Anwendungsbeispiele des Forschungsprojekts DizRuPt präsentiert. Jedes der vier Anwenderunternehmen stellt dabei zwei konkrete Herausforderungen mitsamt der Lösungsprozesse vor, die es im Projekt zu bewältigen hatte.

Kapitel 7 legt abschließend sechs Tipps für den Transfer der Ergebnisse in die Praxis dar.

Mit den in diesem Buch vorgestellten Ergebnissen wird ein **signifikanter Beitrag zum Stand der Forschung** der Betriebsdaten-gestützten Produktplanung geleistet. Zuvorderst liefert das Buch mit dem Referenzprozess und den dazugehörigen Methoden eine erste umfassende und umfangreich validierte Lösung zur Betriebsdaten-gestützten Produktplanung. Diese zeichnet sich durch ihre systematische Vorgehensweise und praxisnahe Anwendbarkeit aus. Produzierende Unternehmen werden durch den Referenzprozess befähigt, zukünftige Produktgenerationen auf Basis von Betriebsdaten-Analysen zu planen. Darüber hinaus stellt das Buch mit den Umsetzungsempfehlungen und der IT-Unterstützung wesentliche Bausteine für eine effiziente Umsetzung des Referenzprozesses in der Praxis bereit. Mit den Einblicken in die Anwendungsbeispiele und den Tipps für den Transfer in die Praxis bietet das Buch außerdem zahlreiche wertvolle Hinweise für produzierende Unternehmen, welche die Betriebsdaten-gestützten Produktplanung eigenständig angehen wollen. Zusammengefasst stellt das vorliegende Buch die erste ausführliche wissenschaftliche und praktische Auseinandersetzung mit der Betriebsdaten-gestützten Produktplanung dar und trägt damit maßgeblich zur Erschließung der Potentiale dieses hochrelevanten Zukunftsthemas bei.

Aufbauend auf diesen Ergebnissen ergeben sich spannende **zukünftige Forschungsbedarfe**. Dabei ist zum Beispiel die Kombination von Betriebsdaten mit weiteren verfügbaren Daten zu nennen. Gerade im B2C-Bereich werden im Internet riesige Datenmengen erzeugt (z. B. in Form von Kundenrezensionen), deren Kombination mit den in diesem Buch betrachteten Betriebsdaten weitere Potentiale zur umfassenden Wissensgenerierung aus Daten verspricht. Eine andere Erweiterung drängt sich hinsichtlich der Aufgaben des Produktmanagements auf. Hier ist zu prüfen, wie die vorhandenen Betriebsdaten auch für andere Aufgaben als die strategische Planung neuer Produktgenerationen genutzt werden können. Aus einer etwas technischeren Sicht stellt sich zudem die Frage, mit welchen Maßnahmen die erforderlichen Betriebsdaten frühzeitig und aufwandsarm beschafft werden können und wie die Betriebsdaten-Erfassung von Anfang an so gestaltet werden kann, dass die Daten sich für vielfältige Use Cases gleichermaßen eignen.

Abkürzungsverzeichnis

ABS	Acrylnitril-Butadien-Styrol
AD-Wandler	Analog-Digital-Wandler
API	Application Programming Interface
atBOM	Asset-Typ Komponentenstruktur
ATM	Automated Teller Machine (Geldautomat)
AutoML	Automated Machine Learning
AWS	Amazon Web Services
B2A	Business-to-Analytics
B2B	Business-to-Business
B2C	Business-to-Customer
BDA	Big Data Analytics
BOL	Beginning of Life
BOM	Stücklistenstruktur
CBM	Condition Based Maintenance
CMS	Content Management System
CPS	Cyber-Physical-System
CPU	Central Processing Unit
CRISP-DM	Cross-Industry Standard Process for Data Mining
CSV	Comma-separated values
eBOM	Engineering-Stückliste
EOL	End of Life
ERP	Enterprise Resource Planning
Fa.	Firma
FFT	Fast Fourier Transformation
FH SWF	Fachhochschule Südwestfalen
GPU	Graphics Processing Unit
I/O	Input/Output
I2C	Inter-Integrated Circuit
IDE	integrierte Entwicklungsumgebung
IEPE	Impedanzwandler-Elektronik
IoT	Internet of Things
IP	Internet Protocol
IT	Information Technology

ITS	Intelligentes technisches System
KI	Künstliche Intelligenz
KMU	Kleine mittelständische Unternehmen
KPI	Key Performance Indikator
MEMS	Micro-Electro-Mechanical System
MES	Manufacturing Execution System
ML	Machine Learning
MOL	Middle of Life
MQTT	Message Queuing Telemetry Transport
NAS	Network Access Server
OPC UA	Open Platform Communications Unified Architecture
PDF	Portable Document Format
PLM	Product Lifecycle Management
PoE	Power over Ethernet
PU	Polyurethan
RPi	Raspberry Pi
sBOM	Service-Stückliste
SOP	Start of Production
SPI	Serial Peripheral Interface
SPS	Speicherprogrammierbare Steuerung
TPU	Tensor Processing Unit
USB	Universal Serial Bus
ZUGFeRD	Zentraler User Guide des Forums elektronische Rechnung Deutschland

Autorenverzeichnis

Prof. Dr.-Ing. Roman Dumitrescu

Jahrgang 1981, ist Direktor am Fraunhofer-Institut für Entwurfstechnik Mechatronik IEM und Leiter des Fachgebiets »Advanced Systems Engineering« am Heinz Nixdorf Institut der Universität Paderborn. Sein Forschungsschwerpunkt ist die Produktentstehung intelligenter technischer Systeme. In Personalunion ist Prof. Dumitrescu Geschäftsführer des Technologienetzwerks Intelligente Technische Systeme OstWestfalenLippe (it's OWL). Er ist unter anderem Mitglied in der deutschen Akademie der Technikwissenschaften (acatech), Fachbeirat der Westfalen Weser Energie Gruppe, Mitglied im Expertenkreis des Innovationsdialogs der Bundesregierung, Forschungsbeirat der Forschungsvereinigung 3-D MID e.V. sowie Verwaltungsrat des RKW Kompetenzzentrums.



Dr.-Ing. Christian Koldewey

Jahrgang 1989, ist Oberingenieur der Fachgruppe Advanced Systems Engineering am Heinz Nixdorf Institut der Universität Paderborn. Er promovierte an der Universität Paderborn unter der Leitung von Prof. Dr.-Ing. Jürgen Gausemeier zu Smart Services im produzierenden Gewerbe. Zuvor studierte er Maschinenbau an der Universität Paderborn und der Fachhochschule Bielefeld. Seine aktuellen Forschungsschwerpunkte sind die Transformation produzierender Unternehmen zu Smart Service Anbietern und Datenökosystemen in der Produktion sowie die digitale Transformation im Allgemeinen.



M.Sc. Maurice Meyer

Jahrgang 1992, studierte Wirtschaftsingenieurwesen an der Fachhochschule Bielefeld und Mechatronik an der Technischen Hochschule Köln. Seit 2018 ist er wissenschaftlicher Mitarbeiter am Heinz Nixdorf Institut der Universität Paderborn in der Fachgruppe Advanced Systems Engineering von Prof. Dumitrescu. Seine Forschungsschwerpunkte liegen in der Integration von Betriebsdaten-Analysen in die strategische Produktplanung, der Produktportfolio-Planung sowie der Strategieentwicklung. In diesen Bereichen leitete er mehrere Forschungs- und Industrieprojekte, darunter auch das Konsortialforschungsprojekt DizRuPt – Datengestützte Produktplanung, dessen Ergebnisse im vorliegenden Buch präsentiert werden.



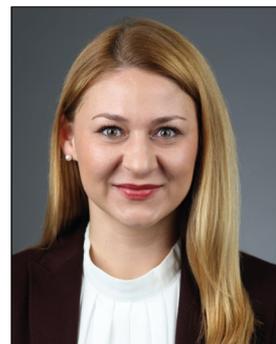
M.Sc. Melina Panzner

Jahrgang 1990, studierte (Medien)Wirtschaft im Bachelor und Interdisziplinäre Medienwissenschaften mit Informatikschwerpunkt an der Universität Bielefeld. Nach einem Jahr Tätigkeit als wissenschaftliche Mitarbeiterin am Fraunhofer Institut für Entwurfstechnik und Mechatronik wechselte sie zum Heinz Nixdorf Institut der Universität Paderborn in die Fachgruppe Advanced Systems Engineering. Sie forscht dort seit März 2019 im Bereich Industrial Analytics. Ihr Forschungsschwerpunkt ist die datengestützte Produktplanung.



M.Sc. Ingrid Wiederkehr

Jahrgang 1992, studierte Wirtschaftsingenieurwesen mit der Fachrichtung Maschinenbau an der Universität Paderborn. Seit Februar 2020 ist sie wissenschaftliche Mitarbeiterin am Heinz Nixdorf Institut der Universität Paderborn in der Fachgruppe Advanced Systems Engineering bei Prof. Dr.-Ing. Roman Dumitrescu. Sie leitet den Bereich Business Engineering. Ihre Tätigkeitsschwerpunkte sind die Strategische Produktplanung sowie das Innovationsmanagement. In diesen Bereichen leitet sie Forschungs- und Industrieprojekte. Darüber hinaus betreut sie dazugehörige Lehrveranstaltungen.



M.Sc. Timm Fichtler

Jahrgang 1994, studierte Wirtschaftsingenieurwesen im Bachelor praxisintegriert an der Fachhochschule Bielefeld und im Master an der Universität Paderborn. Seit Dezember 2021 ist er wissenschaftlicher Mitarbeiter am Heinz Nixdorf Institut der Universität Paderborn in der Fachgruppe Advanced Systems Engineering von Prof. Dumitrescu. Seine Forschungsschwerpunkte liegen in der Integration von Data-Analytics-Ansätzen in das Produktmanagement sowie der reifegradbasierten Transformation von Unternehmen zu Smart-Service-Anbietern. In diesen Bereichen betreut er Forschungs- und Industrieprojekte.



M.Eng. Daniel Panick

Jahrgang 1989, ist gelernter Werkzeugmechaniker in der Fachrichtung Stanz- und Umformtechnik und erlangte seinen Bachelor- sowie Masterabschluss im Maschinenbau mit der Fachrichtung Konstruktion und Produktentwicklung an der Fachhochschule Südwestfalen (FH SWF). Nach über fünf Jahren als Projektleiter bei einem mittelständischem Automobilzulieferer für Stanz- und Umformteile wechselte er in die Forschung. Seit Mitte Februar 2020 ist er als wissenschaftlicher Mitarbeiter im Labor für Massivumformung an der FH SWF tätig und verantwortet anwendungsorientierte Forschungs- und Entwicklungsprojekte aus dem Bereich der Umformtechnik sowie der Industrie 4.0.



Dr. Lukas Isenberg

Jahrgang 1987, studierte Management & Economics mit der Fachrichtung Marketing & Vertrieb an der Ruhr-Universität Bochum. Nach seinem Masterstudium promovierte er von 2015 bis 2020 am Sales Management Department der Ruhr-Universität Bochum. Seine Themenschwerpunkte waren Geschäftsmodelle im Kontext der Industrie 4.0, Kleinkundenmanagement und Vertriebssteuerung in B2B-Unternehmen. In diesen Bereichen betreute er Lehrveranstaltungen und leitete ein Forschungs- und Industrieprojekt. Nach seiner Promotion war er als Unternehmensberater bei *Prof. Schmitz & Wieseke | Sales Management Consulting* sowie als freiberuflicher Berater tätig.



Dr.-Ing. Thomas Dickopf

Jahrgang 1985, erlangte 2012 seinen Diplomabschluss in der Fachrichtung Maschinenbau mit angewandter Informatik an der Technischen Universität Kaiserslautern. Von 2013 bis 2018 promovierte er parallel zu seiner Zeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Virtuelle Produktentwicklung der Technischen Universität Kaiserslautern auf dem Gebiet der modellbasierten Systementwicklung (MBSE). Seit Mai 2018 ist Thomas Dickopf bei CONTACT Software tätig. Nach vier Jahren im Produktmanagement als Analyst und Berater mit den Schwerpunkten MBSE und IoT, widmet er sich seit Anfang 2022 dem Aufbau der neuen CONTACT Research Abteilung.



Dr.-Ing. Christo Apostolov

Jahrgang 1986, erlangte 2009 einen Bachelor-Doppelabschluss in der Fachrichtung Maschinenbau von der Technischen Universität Sofia, Bulgarien und dem Karlsruher Institut für Technologie, Deutschland. Seine Ausbildung setzte er in der Fachrichtung Material- und Produktionswissenschaften an der Technischen Universität Kaiserslautern weiter fort und erlangte den Master-Abschluss in 2014. Von 2014 bis 2019 war er als wissenschaftlicher Mitarbeiter am Lehrstuhl für Virtuelle Produktentwicklung (VPE) der Technischen Universität Kaiserslautern tätig und verfolgte das Ziel einer Promotion auf dem Gebiet der modellbasierten Systementwicklung. Seit September 2019 ist er als Analyst und Berater mit den Schwerpunkten PLM und IoT bei CONTACT Software tätig.



Dipl.-Ing. Ian Altmann

Jahrgang 1984, studierte an der Technischen Universität Berlin Informationstechnik im Maschinenwesen und konnte während dieser Zeit praktische Erfahrungen in der Forschung am Fraunhofer Institut im Bereich Produktionssysteme sammeln. Anschließend arbeitete er als Softwareentwickler in der Automobilindustrie und verantwortete die Entwicklung eines BI-gestützten Qualitätsmanagement-Tools. 2019 wechselte er zu CONTACT Software ins Produktmanagement bei CONTACT Software. Als Projektingenieur entwickelte er in verschiedenen Kunden- und Forschungsprojekten industrielle IoT-Anwendungen, und wirkte an Themen wie Konnektivität, Standardisierung und Data Analytics mit. Seit 2022 ist er Mitglied im CONTACT Research Team.



M.Sc. Andreas Saum

Jahrgang 1990, ist gelernter Bankkaufmann und erlangte 2020 seinen Masterabschluss in Wirtschaftsinformatik mit Schwerpunkt Industrielle Informationssysteme an der Carl von Ossietzky Universität Oldenburg. Sein Schwerpunkt liegt im Bereich Internet of Things und Industrie 4.0. Er arbeitet seit 2014 bei CONTACT Software und ist als Team- und Projektleiter im Bereich IoT tätig.



B.Eng. Moritz Schilling

Jahrgang 1992, studierte Maschinenbau an der Hochschule für angewandte Wissenschaften Coburg. Seit Juni 2019 ist er als Ingenieur in der Fachabteilung Virtuelles Engineering & Simulation im Unternehmen LASCO Umformtechnik GmbH tätig. Seine Tätigkeitsschwerpunkte liegen in der virtuellen Inbetriebnahme sowie Digitalisierung von vollautomatisierten Schmiedelinien für die Kalt- und Warmumformung von Schmiedeteilen. In diesen Bereichen setzt er Kunden- sowie Forschungsprojekte um.



Dr.-Ing. Ingo Kaiser

Jahrgang 1979, ist einer der Mitbegründer des Miele Geschäftsbereichs „Smart Home“ und leitete das strategische Unternehmensprojekt, welches zur Gründung des Geschäftsbereichs führte. Zuvor arbeitete er als Leiter Innovationspotentiale an neuen Geschäftsfeldern und -modellen sowie an kundenorientierten Use Cases im Bereich Smart Home. Mittlerweile leitet er die Abteilung "Cross-Divisional Digitalization" bei Weidmüller, einem Hersteller von industriellen Verbindungslösungen. Ingo Kaiser wurde 2009 am Heinz Nixdorf Institut der Universität Paderborn mit einer Arbeit über die Entwicklung mechanisch-elektronischer Systeme in spritzgegossenen, räumlichen Schaltungsträgern promoviert.



M.Sc. Stefan Wecker

Jahrgang 1988, studierte Wirtschaftsingenieurwesen mit Schwerpunkt Elektrotechnik an der Universität Paderborn. Seit Dezember 2017 ist er als Ingenieur bei Diebold Nixdorf tätig. Seine Tätigkeitsschwerpunkte liegen in der Leitung und Durchführung von Forschungsprojekten im Themenfeld Industrie 4.0, IoT und Smart Service sowie der Elektronikentwicklung von Cash Technology Hardware.



Dr.-Ing. Olaf Knospe

Jahrgang 1968, studierte Maschinenbau mit der Vertiefung Gebäudetechnik an der Technischen Universität Berlin. Nach mehrjährigen internationalen Arbeitsaufenthalten und einer Promotion im Bereich Ingenieurwesen, leitet er seit April 2005 die Abteilung Forschung und Entwicklung bei der Westaflexwerk GmbH in Gütersloh. Seine Tätigkeitsschwerpunkte liegen in der Anwendungsforschung sowie der Entwicklung von Produkten für den Maschinenbau und der Lüftungstechnik.

**Außerdem danken wir für ihre Mitarbeit (in alphabetischer Reihenfolge):**

Leah Allelein, Harald Barnickel, Oliver Dietz, Dr.-Ing. Maximilian Frank, Claudio Geisert, Martin Gogolin, Mathis Jahn, Christian Lahoda, Gerald Lobermeier, Prof. Dr.-Ing. Michael Marré, Lukas Peters, Michael Schnabel, Michael Siewert, Deniz Simsek, Prof. Dr. h. c. Dr.-Ing. Eckart Uhlmann, Christian Vogel sowie den zahlreichen Teilnehmern der über das Konsortium hinausgehenden Interviewstudien, Umfragen und Workshops.

Vorveröffentlichungen

- [DA22] DICKOPF, T.; APOSTOLOV, C.: Closed-Loop Engineering Approach for Data-Driven Product Planning. *Proceedings of the Design Society*, (2), 2022, S. 373–382
- [Dic22] DICKOPF, T.: Closed-Loop-Engineering für die Produktplanung. *AUTOCAD & Inventor Magazin*, (35)1, 2022, S. 52–53
- [MFK+22a] 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 (e14), 2022
- [MFK+22b] MEYER, M.; FICHTLER, T.; KOLDEWEY, C.; DUMITRESCU, R.: How can Data Analytics Results be Exploited in the Early Phase of Product Development? 13 Design Principles for Data-Driven Product Planning. *AMCIS 2022 Proceedings*, 9, 2022
- [MFM+20a] MEYER, M.; FRANK, M.; MASSMANN, M.; DUMITRESCU, R.: Research and Consulting in Data-Driven Strategic Product Planning. *Journal of Systemics, Cybernetics and Informatics*, (18)2, 2020
- [MFM+20b] MEYER, M.; FRANK, M.; MASSMANN, M.; DUMITRESCU, R.: Research and Consulting in Data-Driven Strategic Product Planning. In: *IMCIC 2020 (Hrsg.): Proceedings of the 11th International Multi-Conference on Complexity, Informatics and Cybernetics (IMCIC 2020)*. 10.-13. March 2020, Orlando, Florida, USA, International Institute of Informatics and Cybernetics, 2020
- [MFM+20c] MEYER, M.; FRANK, M.; MASSMANN, M.; WENDT, N.; DUMITRESCU, R.: Data-Driven Product Generation and Retrofit Planning. *53rd CIRP Conference on Manufacturing Systems. Procedia CIRP*, (93), 2020, S. 965–970
- [MMD+19] MASSMANN, M.; MEYER, M.; DUMITRESCU, R.; ENZBERG, S. VON; FRANK, M.; KOLDEWEY, C.; KÜHN, A.; REINHOLD, J.: Significance and Challenges of Data-driven Product Generation and Retrofit Planning. *29th CIRP Design 2019. Procedia CIRP*, (84), 2019, S. 992–997
- [MMF+20a] MASSMANN, M.; MEYER, M.; FRANK, M.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Method for data inventory and classification. *53rd CIRP Conference on Manufacturing Systems. Procedia CIRP*, (93), 2020, S. 234–239
- [MMF+20b] MASSMANN, M.; MEYER, M.; FRANK, M.; ENZBERG, S. VON; KÜHN, A.; DUMITRESCU, R.: Framework for Data Analytics in Data-Driven Product Planning. *5th International Conference on System-Integrated Intelligence. Procedia Manufacturing*, (52), 2020, S. 350–355
- [MPK+21] MEYER, M.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: Towards Identifying Data Analytics Use Cases in Product Planning. *54th CIRP Conference on Manufacturing Systems. Procedia CIRP*, (104), 2021, S. 1179–1184
- [MPK+22] MEYER, M.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: 17 Use Cases for Analyzing Use Phase Data in Product Planning of Manufacturing Companies. *Procedia CIRP*, 107, 2022, S. 1053–1058
- [MWK+21] MEYER, M.; WIEDERKEHR, I.; KOLDEWEY, C.; DUMITRESCU, R.: Understanding Usage Data-Driven Product Planning: A Systematic Literature Review. *Proceedings of the International Conference on Engineering Design (ICED21)*. 16.-20. August 2021, Gothenburg, Sweden, Cambridge University Press, 2021, S. 3289–3298
- [MWK+22] MEYER, M.; WIEDERKEHR, I.; KOLDEWEY, C.; DUMITRESCU, R.: Planning the Analysis of Use Phase Data in Product Planning. *Proceedings of the DESIGN Society*, 2, 2022, S. 753–762

- [MWP+22] MEYER, M.; WIEDERKEHR, I.; PANZNER, M.; KOLDEWEY, C.; DUMITRESCU, R.: A Reference Process Model for Usage Data-Driven Product Planning. Proceedings of the 55th Hawaii International Conference on System Sciences (HICSS 2022). 4.-7. Januar 2022, Virtual Event / Maui, Hawaii, USA, 2022
- [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
- [PM22] PANICK, D.; MARRÉ, M.: Konzept zur Sensornachrüstung, Messdaten als Basis zur Kollaboration im Produktionsnetzwerk. In: Zeitschrift für wirtschaftlichen Fabrikbetrieb, Walter de Gruyter Verlag, Berlin/Boston, Germany, 117(12), 2022, S. 896–901
- [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. 32nd CIRP Design Conference. Procedia CIRP, (109), 2022, S. 580–585
- [UDP+20] UHLMANN, E.; DUMITRESCU, R.; POLTE, J.; MEYER, M.; SIMSEK, D.: Datengetriebene Steigerung der Verfügbarkeit/Data-supported root cause analysis to increase the availability of machine tools. Data-driven availability increase. wt Werkstattstechnik online, (110)07-08, 2020, S. 532–535
- [UPS+21] UHLMANN, E.; POLTE, J.; SIMSEK, D.; KOUTRAKIS, N.-S.; EPPING, M.: Hypothesengetriebene Analyse von Ausfallursachen. Zeitschrift für wirtschaftlichen Fabrikbetrieb, (116)4, 2021, S. 263–268
- [WDK+22] WIEDERKEHR, I.; DUMITRESCU, R.; KOLDEWEY, C.; MARRÉ, M.; PANICK, D.: Datennutzung in der Produktionssystementwicklung/Using data for production system development. wt Werkstattstechnik online, (112)04, 2022, S. 264–268

Das Heinz Nixdorf Institut – Interdisziplinäres Forschungszentrum für Informatik und Technik

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

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

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

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

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

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

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

Zuletzt erschienene Bände der Verlagsschriftenreihe des Heinz Nixdorf Instituts

- Bd. 381 PLACZEK, M.: Systematik zur geschäftsmodellorientierten Technologieförderung. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 381, Paderborn, 2018 – ISBN 978-3-947647-00-2
- Bd. 382 KÖCHLING, D.: Systematik zur integrativen Planung des Verhaltens selbstoptimierender Produktionssysteme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 382, Paderborn, 2018 – ISBN 978-3-947647-01-9
- Bd. 383 KAGE, M.: Systematik zur Positionierung in technologieinduzierten Wertschöpfungsnetzwerken. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 383, Paderborn, 2018 – ISBN 978-3-947647-02-6
- Bd. 384 DÜLME, C.: Systematik zur zukunftsorientierten Konsolidierung variantenreicher Produktprogramme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 384, Paderborn, 2018 – ISBN 978-3-947647-03-3
- Bd. 385 GAUSEMEIER, J. (Hrsg.): Vorausschau und Technologieplanung. 14. Symposium für Vorausschau und Technologieplanung, Heinz Nixdorf Institut, 8. und 9. November 2018, Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 385, Paderborn, 2018 – ISBN 978-3-947647-04-0
- Bd. 386 SCHNEIDER, M.: Spezifikationstechnik zur Beschreibung und Analyse von Wertschöpfungssystemen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 386, Paderborn, 2018 – ISBN 978-3-947647-05-7
- Bd. 387 ECHTERHOFF, B.: Methodik zur Einführung innovativer Geschäftsmodelle in etablierten Unternehmen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 387, Paderborn, 2018 – ISBN 978-3-947647-06-4
- Bd. 388 KRUSE, D.: Teilautomatisierte Parameteridentifikation für die Validierung von Dynamikmodellen im modellbasierten Entwurf mechatronischer Systeme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 388, Paderborn, 2019 – ISBN 978-3-947647-07-1
- Bd. 389 MITTAG, T.: Systematik zur Gestaltung der Wertschöpfung für digitalisierte hybride Marktleistungen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 389, Paderborn, 2019 – ISBN 978-3-947647-08-8
- Bd. 390 GAUSEMEIER, J. (Hrsg.): Vorausschau und Technologieplanung. 15. Symposium für Vorausschau und Technologieplanung, Heinz Nixdorf Institut, 21. und 22. November 2019, Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 390, Paderborn, 2019 – ISBN 978-3-947647-09-5
- Bd. 391 SCHIERBAUM, A.: Systematik zur Ableitung bedarfsgerechter Systems Engineering Leitfäden im Maschinenbau. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 391, Paderborn, 2019 – ISBN 978-3-947647-10-1
- Bd. 392 PAI, A.: Computationally Efficient Modelling and Precision Position and Force Control of SMA Actuators. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 392, Paderborn, 2019 – ISBN 978-3-947647-11-8
- Bd. 393 ECHTERFELD, J.: Systematik zur Digitalisierung von Produktprogrammen. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 393, Paderborn, 2020 – ISBN 978-3-947647-12-5
- Bd. 394 LOCHBICHLER, M.: Systematische Wahl einer Modellierungstiefe im Entwurfsprozess mechatronischer Systeme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 394, Paderborn, 2020 – ISBN 978-3-947647-13-2

Zuletzt erschienene Bände der Verlagsschriftenreihe des Heinz Nixdorf Instituts

- Bd. 395 LUKEI, M.: Systematik zur integrativen Entwicklung von mechatronischen Produkten und deren Prüfmittel. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 395, Paderborn, 2020 – ISBN 978-3-947647-14-9
- Bd. 396 KOHLSTEDT, A.: Modellbasierte Synthese einer hybriden Kraft-/Positionsregelung für einen Fahrzeugachsprüfstand mit hydraulischem Hexapod. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 396, Paderborn, 2021 – ISBN 978-3-947647-15-6
- Bd. 397 DREWEL, M.: Systematik zum Einstieg in die Plattformökonomie. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 397, Paderborn, 2021 – ISBN 978-3-947647-16-3
- Bd. 398 FRANK, M.: Systematik zur Planung des organisationalen Wandels zum Smart Service-Anbieter. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 398, Paderborn, 2021 – ISBN 978-3-947647-17-0
- Bd. 399 KOLDEWEY, C.: Systematik zur Entwicklung von Smart Service-Strategien im produzierenden Gewerbe. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 399, Paderborn, 2021 – ISBN 978-3-947647-18-7
- Bd. 400 GAUSEMEIER, J. (Hrsg.): Vorausschau und Technologieplanung. 16. Symposium für Vorausschau und Technologieplanung, Heinz Nixdorf Institut, 2. und 3. Dezember 2021, Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 400, Paderborn, 2021 – ISBN 978-3-947647-19-4
- Bd. 401 BRETZ, L.: Rahmenwerk zur Planung und Einführung von Systems Engineering und Model-Based Systems Engineering. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 401, Paderborn, 2021 – ISBN 978-3-947647-20-0
- Bd. 402 WU, L.: Ultrabreitbandige Sampler in SiGe-BiCMOS-Technologie für Analog-Digital-Wandler mit zeitversetzter Abtastung. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 402, Paderborn, 2021 – ISBN 978-3-947647-21-7
- Bd. 403 HILLEBRAND, M.: Entwicklungssystematik zur Integration von Eigenschaften der Selbstheilung in Intelligente Technische Systeme. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 403, Paderborn, 2021 – ISBN 978-3-947647-22-4
- Bd. 404 OLMA, S.: Systemtheorie von Hardware-in-the-Loop-Simulationen mit Anwendung auf einem Fahrzeugachsprüfstand mit parallelkinematischem Lastsimulator. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 404, Paderborn, 2022 – ISBN 978-3-947647-23-1
- Bd. 405 FECHTELPETER, C.: Rahmenwerk zur Gestaltung des Technologietransfers in mittelständisch geprägten Innovationsclustern. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 405, Paderborn, 2022 – ISBN 978-3-947647-24-8
- Bd. 406 OLEFF, C.: Proaktives Management von Anforderungsänderungen in der Entwicklung komplexer technischer Systeme. Dissertation, Fakultät für Maschinenbau, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 406, Paderborn, 2022 – ISBN 978-3-947647-25-5
- Bd. 407 JAVED, A. R.: Mixed-Signal Baseband Circuit Design for High Data Rate Wireless Communication in Bulk CMOS and SiGe BiCMOS Technologies. Dissertation, Fakultät für Elektrotechnik, Informatik und Mathematik, Universität Paderborn, Verlagsschriftenreihe des Heinz Nixdorf Instituts, Band 407, Paderborn, 2022 – ISBN 978-3-947647-26-2