



**Datengetriebene Entscheidungsprozesse in
Großprojekten am Beispiel der Datenwertschöpfungskette der Betriebsführung
und Instandhaltung von Windparks**

Von der Fakultät für Informatik, Wirtschafts- und Rechtswissenschaften der
Carl von Ossietzky Universität Oldenburg zur Erlangung des Grades und Titels

Doktor Ingenieur (Dr.-Ing.)

angenommene Dissertation

von: Herrn Dipl.-Ing. (FH) Dirk Bendlin

geboren am: 05.08.1982 in Eckernförde

Gutachter: Prof. Dr.-Ing. Jorge Marx Gómez und

Weiterer Gutachter: Prof. Dr. rer. nat. Sebastian Lehnhoff

Tag der Disputation: 08.01.2024

Vorwort

Ein so umfangreiches Projekt wie eine Promotion gleicht eher einem Marathon als einem Sprint. Im Gegensatz zum klassischen Marathon kann sich mit fortschreitender Forschung allerdings auch der Weg zum Ziel ändern. Vielleicht ist es ein Geschenk, weder den Weg noch die Herausforderungen zu Beginn des Promotionsvorhabens zu kennen. Jetzt schaue ich mit Dankbarkeit auf die Herausforderungen, die hinter mir liegen und deren Lösung maßgeblich zu dem Erfolg dieser Doktorarbeit beitragen konnten. Zu den Herausforderungen kamen zahlreiche fachliche und private Diskussionen mit Wegbegleitern und Kritikern, die teils unwissend ebenfalls wichtige Impulse geben konnten, um meine Arbeit zu bereichern. Speziell der Austausch mit anderen Doktoranden, etwa im Dissertations-Sprint 2021 oder im Austausch mit der Schreibgruppe der VLBA, zeigte mir, dass ich zwar meinen Weg allein gehen musste, aber auf meiner Reise nicht allein war.

Fachlich bin ich sehr dankbar, dass sich durch diese Arbeit für mich ein Kreis schließen kann, der sich schon zu meinen Studienzeiten öffnete. Im Maschinenbaustudium mit der Fachrichtung Produktionstechnik ging es um den effizienten Einsatz begrenzter Ressourcen zur Steigerung der Produktivität. Umso erstaunter war ich in meiner Berufslaufbahn über ineffiziente Arbeiten, die basierend auf intuitiven Entscheidungen aus dem Bauch heraus durchgeführt wurden: von der Angebotserstellung über die Warenbeschaffung bis hin zum Projektmanagement von Großprojekten der Offshore-Windenergie. Oft waren es hochbezahlte Entscheidungsträger, die am Ende eines unterschiedlich gearteten Entscheidungsprozesses aus einem Gefühl heraus entschieden. Parallel dazu wurde in der Gesellschaft der Wert von Daten immer offensichtlicher. Angetrieben durch Erfolgsgeschichten von Silicon-Valley-Konzernen wurde der Ruf nach einer neuen Fachrichtung der Data-Science laut. Gleichzeitig sorgte der Hype um Buzzwords wie Big Data, Künstliche Intelligenz, Machine Learning oder Large Language Modells wie Chat-GPT dafür, dass Data-Science mit „Raketenwissenschaften“ gleichgesetzt wurde.

Um Data-Science für datengetriebene Entscheidungsprozesse zu nutzen, muss eine Entmystifizierung einsetzen. Dafür müssen Entscheidungsträger in der Lage sein, den Wert von Datenanalysen zur Lösung von Geschäftsproblemen zu bewerten und Werkzeuge nach ihrem Nutzen auszuwählen. Nur so kann Data-Science einen nachhaltigen und effizienten Mehrwert für Entscheidungsträger jeglicher Art bieten. Ich hoffe, dass diese Arbeit einen bescheidenen Anteil dazu beitragen kann, Entscheidungen zukünftig datengetriebener und effizienter zu gestalten.

Danksagung

Ohne Professor Dr.-Ing. Jorge Marx Gómez würde es die Arbeit in dieser Form nicht geben. Ich bedanke mich für die richtigen Worte zur richtigen Zeit und zahlreiche fachliche und menschliche Hilfestellungen innerhalb der Betreuung. Meinen Kollegen und Mitdoktoranden von der VLBA gilt mein weiterer Dank für viele fachlichen Diskussionen und aufmunternde Worte, wenn die Forschung ins Stocken kam. Es war ein klasse Gefühl, Teil eures Teams zu sein. Ein besonderer Dank gilt dabei der Schreibgruppe um Ali Akyol, Bettina Schuhmann, Dr. Jakob Nonnenmacher, aber auch Dr. Volkan Gizli und Viktor Dmitriyev.

Professor Sebastian Lehnhoff danke ich für seine zielgerichteten Hinweise und kritische Nachfragen, die ebenfalls maßgeblich zur Verbesserung der Qualität der vorliegenden Arbeit beitragen konnten. Neben meiner akademischen Familie geht mein Dank an meine beruflichen Stationen und die ehemaligen Kollegen des Fraunhofer IWES, speziell Gerrit Wolken-Möhlmann, Jakob Schumacher, Maxim Hartung und Jannis Klar, die mich in das akademische Arbeiten einführten und immer an mich geglaubt haben. Ein weiterer Dank gilt meinen Kollegen der Ramboll Deutschland GmbH, darunter meinem Vorgesetzten Jens Kalin für seine Unterstützung und die eingeräumten Freiräume. Für alle fachlichen Diskussionen und die Unterstützung innerhalb des Forschungsprojektes WiSA Big Data und darüber hinaus bedanke ich mich bei meinen Kollegen Dr. Moritz Werther Häckell, Marie-Antoinette Schwarzkopf, Hanna Kaddoura, Alicja Kucewicz, Dr. Britta Hackbarth, Dr. Jan Fischer und Ursula Smolka. Speziell in den besonders herausfordernden Phasen einer Dissertation hat mir der Austausch mit Gleichgesinnten sehr geholfen. Ein besonderer Dank gilt unseren Industrie Partnern der Deutschen Windtechnik, vor allem Simon Geiselsöder, unterstützt von Benedikt Börgel, für ihre Unterstützung und die tiefen Einblicke in reale Geschäftsprobleme und Prozesse. Ebenfalls danke ich Vattenfalls Sebastian Kaus, Kira Kaufmann und Adel Haghani und Ocean Breeze mit Alexander Lowag sowie Iberdrola für die Unterstützung des Forschungsprojektes. Vielen Dank auch an Forwind unter Leitung von Dr. Henrik Heißelmann und fachlicher Unterstützung von Dr. Matthias Wächter für die Koordination dieses komplexen Forschungsprojektes.

Gegenwind und Kritik waren eine ständige Begleitung meiner Arbeit, hiermit möchte ich mich bei allen Zweiflern und Kritikern herzlich bedanken, die Kritik war eine wertvolle Inspiration, die mir geholfen hat, meine Arbeit weiter zu schärfen und zu stärken. Als Junge von der Küste habe ich es gelernt mit Gegenwind umzugehen und ihn als Antrieb zu nutzen. Die Küste hat mich gelehrt, Herausforderungen anzunehmen und sie in positive Energie umzuwandeln. So folgt nach jedem Sturm, Unwetter oder dunkelster Nacht irgendwann der Sonnenschein. Als erfahrener Projektmanager komplexer Offshore-Windparkprojekte nutze ich Gegenwind und Herausforderungen, um innovative Lösungen zu finden. So konnte ich neue Wege gehen und mich kontinuierlich weiterentwickeln und so menschlich und professionell wachsen. Während ich dies schrei-

be, wird mir bewusst, wie schwierig es ist hier einen Weg zu finden sich bei allen Beteiligten zu bedanken. Daher möchte ich mich hier bei allen Studierenden, wissenschaftlichen Hilfskräften und Unterstützende jedweder Art bedanken, die zum Gelingen dieser Arbeit beigetragen haben.

Zum Schluss gilt mein großer Dank den wichtigsten Begleitern und Unterstützern meiner Familie. Liebe Olivia, lieber Maximilian und lieber Tom, ihr seid mein Zuhause und meine Kraftquelle, die das alles nur möglich gemacht haben, vielen Dank für all die Liebe und Unterstützung, die wir teilen dürfen. Meiner Mutter danke ich für den Glauben und die Unterstützung, die nur die Liebe einer Mutter zu geben vermag. Meinem Vater danke ich für anregende Fragen und philosophische Diskurse, die mein Denken nachhaltig prägen. Ihr seid der Grund für meine starken Wurzeln, meine Durchhaltekraft.

Dirk Bendlin

Hamburg, Januar 2024

Zusammenfassung

Aktuell wird die Wertschöpfung aus Daten bei der Entscheidungsfindung von Organisationen häufig nicht ausreichend berücksichtigt. Dies ist unter anderem dem Aspekt geschuldet, dass Aufwand und Nutzen von Datenanalysen von Data-Scientist*innen sowie Anwendenden unterschiedlich betrachtet und eingeschätzt werden. Während Data-Scientist*innen in der Datenaufbereitung und -analyse versiert sind, fehlt ihnen in der Regel Anwenderwissen zur Nutzenbewertung. Anwendende hingegen können zwar den Nutzen von Datenanalysen bewerten, allerdings nicht den zugehörigen Aufwand. Mittels einer Brücke zwischen beiden Bereichen könnte das Potenzial von Daten bei Entscheidungsfindungen von Organisationen effizienter genutzt werden. Visualisierungen von Datenwertschöpfungsketten könnten diese Brücke für datengetriebene Entscheidungsprozesse schlagen. Bis jetzt finden sich in der Forschung allerdings nur Ansätze, die sich mit Teilfragen der Visualisierung und Analyse von Datenwertschöpfungsketten befassen, ohne dabei ein zusammenhängendes Evaluationsmodell zu beschreiben. Die vorliegende Arbeit stellt sich dieser Herausforderung und entwickelt ein Evaluationsmodell zur Analyse und Visualisierung von Datenwertschöpfungsketten anhand von Fallbeispielen der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks.

Bestehende Modelle beschränken sich entweder auf einzelne Teile des Datenanalyseprozesses oder konzentrieren sich auf den Wertschöpfungsaspekt, wobei es oftmals an objektiven Evaluationskriterien fehlt. In dieser Studie wird ein Evaluationsmodell entwickelt, das die gesamte Datenwertschöpfungskette einbezieht und sich auf objektive Bewertungskriterien stützt. Die Hauptforschungsfrage, der hier nachgegangen wird, lautet: *Wie kann eine Datenwertschöpfungskette evaluiert, visualisiert und analysiert werden?* Sie wird in drei Teilschritten beantwortet.

Die Teilforschungsfrage eins lautet: *Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?* Um sie zu beantworten, wird eine Definition der Datenwertschöpfungskette aus einer Literaturrecherche und etablierten datengetriebenen Entscheidungsprozessen abgeleitet. Diese Definition fungiert als Basis für Interviews mit Expert*innen, die in Form von Aktionsforschung mit Forschungs- und Industriepartnern des *WiSA Big Data*¹-Projekts ausgeführt wurden. Im Ergebnis wurden 53 Online-Interviews mit Expert*innen der Industriepartner Deutsche Windtechnik, Ocean Breeze, Iberdrola und Vattenfall sowie der Forschungspartner Carl von Ossietzky Universität Oldenburg (Abteilung Wirtschaftsinformatik/Very Large Business Applications), OFFIS e. V. Institut für Informatik,

¹ Nach dem Zuwendungsbescheid lautet der Forschungsprojektname *WiSAbigdata* (FKZ: 03EE3016E); zur einfacheren Lesbarkeit wird dieser Name innerhalb der gesamten Arbeit auf *WiSA Big Data* vereinfacht.

Universität Duisburg Essen, FORWIND² und Fraunhofer IWES³ durchgeführt, um die organisatorischen Strukturen und Herausforderungen in der Betriebsführung und Instandhaltung von Onshore- sowie Offshore-Windparks zu identifizieren und zu evaluieren.

Diese Interviews mit Expert*innen wurden weiterhin genutzt, um die zweite Teilforschungsfrage zu beantworten: *Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, können mit Datenanalysen beantwortet werden?* Im Ergebnis wurden durch *Question-Storming* 184 Datenprodukte identifiziert. Daraus wurden die Top-3- und Top-12-Datenprodukte durch eine Nutzwertanalyse mit den Forschungs- und Industriepartnern abgeleitet. Gleichzeitig wurde ein Kategorisierungssystem für die Datenprodukte etabliert und eingeführt. Um den Detaillierungsgrad dieser Top-Datenprodukte zu erhöhen, wurde das ursprüngliche Modell der Datenwertschöpfungskette durch eine weitere Literaturrecherche, bei der 21 Canvas-Modelle identifiziert wurden, zu einem Datenwertschöpfungsketten-Canvas erweitert.

Die dritte Teilforschungsfrage lautet: *Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten und Nutzen optimiert werden?* Damit diese Frage beantwortet werden kann, wurde das Bewertungsmodell durch eine Literaturrecherche um ein Bewertungs- und Kennzahlensystem (KPI) erweitert. Um einen Kosten-Nutzen-Vergleich besser durchführen zu können, ist es modular aufgebaut und kann auf die Komponenten der Datenwertschöpfungskette heruntergebrochen werden. Im Ergebnis wurden das Kategorisierungssystem, die Datenwertschöpfungsketten-Ontologie, das Bewertungsmodell und das Kennzahlensystem als Proof of Concept durch einen Software-Prototyp visualisiert und durch Fallbeispiele mit den Industriepartnern evaluiert. Mittels der Untersuchung konnte die Wissensbasis innerhalb der Data-Science mit einem Evaluationsmodell für Datenwertschöpfungsketten erweitert werden. Vorhandene Modelle konzentrierten sich auf Teile des Datenanalyseprozesses oder waren eher auf den Aspekt der Wertschöpfung für die Anwendenden ausgerichtet. Den ermittelten Modellen fehlten indes objektive Kennzahlen und eine Visualisierung, die im Rahmen dieser Arbeit ergänzt werden konnte. In der Anwendungsdomäne *Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks* konnte das Evaluationsmodell klare Optimierungspotenziale entlang der individuellen Datenwertschöpfungsketten identifizieren. Die Übertragbarkeit und Erweiterbarkeit der Modelle zu untersuchen, bleibt mithin der weiteren Forschung vorbehalten.

² Forschungszentrum für Windenergieforschung der Universitäten Bremen, Hannover und Oldenburg.

³ Fraunhofer-Institut für Windenergiesysteme.

Abstract

Currently, value creation from data is often not sufficiently considered in organizational decision-making processes, thus missing out on the potential it has for optimising those processes. One of the reasons for this is that the value and benefits of data analytics are misjudged. Data Scientists are proficient in preparing and analysing data but they typically lack the user knowledge to assess their benefits. Users may be able to assess the benefits of data analysis, but not the associated costs. Bridging this gap between the two could more effectively harness the potential of data in organizational decision making. Visualizations of data value chains could provide this bridge for data-driven decision-making processes. To date, however, there are only approaches that address partial issues of visualization and analysis of data value chains without describing a coherent evaluation model. This study is dedicated to developing an evaluation model that evaluates, visualises and analyses data value chains in organizations using the example of operations management and maintenance of offshore wind farms.

The main research question addressed in this work is: *How can a data value chain be evaluated, visualized and analyzed?* The study is divided into three sub-research questions: how are data value chains defined, which relevant questions, i. e., data products, in the application domain can be answered with data analytics, and which parts of the data value chain could be optimized in terms of cost/benefit. To answer the first sub-question, a definition of a data value chain is derived from a literature review and existing data-driven decision-making processes. This definition forms the basis for the expert interviews with research and industry partners of the *WiSA Big Data project* (FKZ: 03EE3016E) and is evaluated in the form of action research. As a result, 53 online expert interviews were conducted with the industry partners Deutsche Windtechnik, Ocean Breeze, Iberdrola, Vattenfall and the research partners Carl von Ossietzky University Oldenburg (Business Informatics/ Very Large Business Applications), OFFIS e. V. Institute for Informatic, University Duisburg Essen, FORWIND⁴ and Fraunhofer IWES⁵ in order to identify the organizational structures and challenges in the operation and maintenance of offshore wind farms.

The expert interviews were also used to answer the second sub-research question, *Which relevant questions, i. e., data products, in the application domain can be answered with data analytics?* As a result, 184 data products were identified through QuestionStorming. From these, the top 3 and top 12 data products were derived through a utility analysis with the research and industry partners. In parallel, a categorization system for the data products was created and implemented.

⁴ Forschungszentrum für Windenergieforschung der Universitäten Bremen, Hannover und Oldenburg.

⁵ Fraunhofer-Institut für Windenergiesysteme.

To increase the level of detail of the top data products, the original data value chain model was expanded into a data value chain canvas through literature review identifying 21 canvas models.

The third sub-research question, *Which parts of the data value chain could be optimized in terms of cost/benefit?*, was answered by deriving objective evaluation criteria from the literature. For this purpose, the evaluation model was extended to include an evaluation and key performance indicator (KPI) system. To better perform a cost-benefit comparison, it is modular and can be broken down into the components of the data value chain. Consequently, the categorization system, the data value chain ontology, the evaluation system, and the KPI system were visualized as a proof of concept by a software prototype and evaluated by case studies with the industry partners. By visualizing the results with a Sankey diagram, data science and application experts can quickly identify optimization potential.

The study added an evaluation model for data value chains to the knowledge base within data science. Existing models focused on parts of the data analysis process or were more focused on the value creation aspect for users. However, the identified models lacked objective evaluation criteria and visualisation, which could be added with this work. As an area of application, the domain of operations management and maintenance in offshore wind farms was chosen, where the evaluation model was able to identify significant optimization potential along the individual data value chains. Although the transferability of the model was considered during development, it could not be verified during the course of this work. Thus, there is room for future research to investigate the transferability and extensibility of the models.

Inhaltsverzeichnis

Abkürzungsverzeichnis und Akronyme.....	III
Symbolverzeichnis.....	V
Abbildungsverzeichnis.....	VI
Tabellenverzeichnis	IX
1 Einleitung.....	1
1.1 Problemstellung.....	2
1.2 Anwendungsdomäne Onshore- und Offshore-Windparks.....	3
1.3 Motivation.....	4
1.4 Zielsetzung.....	5
1.5 Einordnung der gewählten Forschungsmethoden in das Methodenspektrum der Wirtschaftsinformatik.....	7
1.6 Aufbau der Arbeit.....	9
2 Data-Science – Grundlagen	12
2.1 Begrifflichkeiten Data-Science	12
2.2 Datengetriebene Entscheidungsfindung	15
2.3 Datenwertschöpfungsketten.....	22
2.4 Rahmenbedingungen von Datenwertschöpfungsketten.....	26
2.5 Data-Governance und Datenqualität	27
2.6 Data-Science-Teams.....	30
3 Evaluationsmodell und Visualisierung der Datenwertschöpfungskette.....	34
3.1 Qualitative Inhaltsanalyse der Literaturrecherche.....	34
3.2 Evaluationsmodell.....	36
3.3 Datenprodukte und Kategorisierungssystem	38
3.4 Bewertungsmodell.....	40
3.5 Datenwertschöpfungsketten-Ontologie	46
3.6 Kennzahlensystem.....	59
3.7 Visualisierung der Datenwertschöpfungskette durch Software-Prototyp.....	67
4 Grundlagen zur Evaluation innerhalb der Anwendungsdomäne	76
4.1 Herausforderungen	76
4.2 Planung von Interviews mit Expert*innen.....	78
4.3 Durchführung der Interviews mit Expert*innen	80
4.4 Analyse	82
5 Einführung Windenergie	85
5.1 Unterschiede zwischen Onshore- und Offshore-Windparks.....	85
5.2 Projektphasen Offshore-Windparks	86
5.3 Technische Bestandteile eines Offshore-Windparks.....	89
5.4 Prozesse, Rollen und Logistik der Betriebsführung und Instandhaltung	94

6	Fallbeispiele Betriebsführung und Instandhaltung Onshore- und Offshore-Windparks	101
6.1	Fallbeispiel Vattenfall.....	102
6.2	Fallbeispiel Iberdrola.....	110
6.3	Fallbeispiel Ocean Breeze.....	111
6.4	Fallbeispiel Deutsche Windtechnik.....	118
7	Schlussbetrachtung.....	126
7.1	Zusammenfassung	126
7.2	Limitationen und weiterer Forschungsbedarf	127
7.3	Theoretische und praktische Implikationen.....	134
7.4	Ausblick	139
	Anhang	142
8	Literaturverzeichnis.....	267

Abkürzungsverzeichnis und Akronyme

BVI	Business Value of Information (Geschäftswert der Informationen)
BMC	Business Model Canvas
CAPEX	Capital Expenditures (Investitionskosten)
CMS	Condition Monitoring System
COVID-19	Die durch SARS-CoV-2 ausgelöste Epidemie des Corona-Virus im Jahr 2019
CRISP DM	Cross Industry Standard Process for Data Mining
CTV	Crew Transfer Vessel
DAGO	Data-Governance
DAMA	Datenmanagement
DANA	Datenanalyse
DAQ	Datenakquise
DEC	Decision (Entscheidung)
DIKW	Data, Information, Knowledge, Wisdom
DWK	Datenwertschöpfungskette
EN	European Norm
FDMS	Foundational Methodology for Data-Science
ForWind	Forschungszentrum für Windenergieforschung der Universitäten Bremen, Hannover und Oldenburg
HTML	Hypertext Markup Language
ISP	Individual Service Provider (Individueller Service Anbieter)
IWES	Institut für Windenergiesysteme
KDD	Knowledge Discovery in Databases
KPI	Key Performance Indicator
OFTO	Offshore Transmission Owner
OPEX	Operational Expenditures (Betriebskosten)
QFT	Question Formulation Technique
RoA	Return on Ambition

ROA _{DWK}	Return on Ambition Datenwertschöpfungskette
RoI	Return on Investment
ROI	Return on Information
ROI _{DWK}	Return on Information Datenwertschöpfungskette
SCADA	Supervisory Control and Data Acquisition
SHM	Structural Health Monitoring
SOV	Service Operation Vessel
TCO	Total Cost of Ownership
TDSP	Team Data-Science Process
WiSA	Wind farm Site Assistant (WiSA) for decision support using Big Data
XML	Extensible Markup language

Symbolverzeichnis

A_i	Handlungsalternativen zur Bewertung
e_{ij}	Zielerfüllungsgrad
g_j	Zielgewichte
m	Endwert
n	Teilnutzen
n_{ij}	Teilnutzenwert
N_j	Gesamtnutzwert
p	Anzahl der Geschäftsprozesse
w_{ij}	Wirksamkeitsmaß
Z_j	Projektspezifisches Zielsystem

Abbildungsverzeichnis

Abb. 1.1: Methodisches Vorgehen zur Beantwortung der Forschungsfragen	10
Abb. 2.1: Bereiche der Entscheidungstheorie (vgl. Nitzsch und Methling 2019, S. 1)..	16
Abb. 2.2: Analytischer Reifegrad (vgl. Gross et al. 2016, S. 1; Taylor 2013).....	18
Abb. 2.3: DIKW-Pyramide (vgl. Ackoff 1999, S. 170 ff.)	18
Abb. 2.4: Voraussetzungen für die Implementierung von Data-Science.....	19
Abb. 2.5: Cross-Industry Standard Process for Data Mining (CRISP-DM) (vgl. Foroughi und Luksch 2018, S. 6)	21
Abb. 2.6: Wertschöpfungskette (vgl. Blume 2020, S. 10; Gudehus 2010, S. 24).....	24
Abb. 2.7: Teile der Datenwertschöpfungskette	24
Abb. 2.8: Typisches Datenakquise-System (vgl. Young 2001, S. 10).....	25
Abb. 2.9: Übersicht über Kernbegriffe und ihre Zusammenhänge (vgl. Heinrichs 2019; Kordon 2020, S. 16).....	26
Abb. 2.10: Richtlinien, Grundsätze und Dimensionen noninvasiver Data- Governance (vgl. Seiner 2014, S. 65).....	28
Abb. 2.11: Noninvasives Data-Governance im Betrieb von Onshore- und Offshore-Windparks (vgl. Seiner 2014, S. 103).....	29
Abb. 3.1: Formen der Inhaltsanalyse (vgl. Mayring 2015, S. 85).....	35
Abb. 3.2: Schematische Übersicht über die Bestandteile der entwickelten Datenwertschöpfungskette	37
Abb. 3.3: Übersicht der Datenprodukte mit der höchsten Priorität	44
Abb. 3.4: BMC-Ontologie (vgl. Osterwalder 2004, S. 44)	47
Abb. 3.5: Erweitertes initiales Business Model Canvas	50
Abb. 3.6: Datenwertschöpfungsketten-Ontologie	55
Abb. 3.7: Datenwertschöpfungsketten-Canvas mit priorisierten Elementen	55
Abb. 3.8: Skalierung Onshore	62
Abb. 3.9: Onshore- im Vergleich zur Offshore-Skalierung am Beispiel der Relevanz..	62
Abb. 3.10: Schematische Darstellung des Software-Prototyps.....	70
Abb. 3.11: Kennzahlentransformation für die Sankey-Visualisierung	72
Abb. 3.12: Entwurf der Datenwertschöpfungsketten-Visualisierung inklusive Whisker-Diagramm	73
Abb. 3.13: Detailansicht auf Datenproduktebene.....	75
Abb. 4.1: Evaluationsplanung Interviews mit Expert*innen	78
Abb. 5.1: Onshore- vs. Offshore-Windströmung	85
Abb. 5.2: Projektbeteiligte Offshore-Windpark (Bendlin et al. 2021, S. 80).....	87
Abb. 5.3: Typische Projektphasen in Offshore-Wind-Projekten (vgl. Hobohm et al. 2013, S. 25; Wegener et al. 2016, S. 105, 184).....	88

Abb. 5.4: Übersichtsgrafik Instandhaltung und Betriebsführung eines Offshore-Windparks (vgl. Bendlin et al. 2021, S. 80).....	88
Abb. 5.5: Schematischer Aufbau einer Offshore-Windenergieanlage mit Gründungsstruktur (vgl. Bailey et al. 2014, S. 9; BSH 2015, S. 19).....	90
Abb. 5.6: Übersicht verschiedener Gründungsstrukturen in Offshore-Windparks ©Ramboll (Bendlin et al. 2021, S. 83)	92
Abb. 5.7: Umspannplattform ©Ramboll (Bendlin et al. 2021, S. 83)	93
Abb. 5.8: IAM-Konzeptmodell für Asset-Management (vgl. IAM 2012, S. 16).....	95
Abb. 5.9: Prozesslandkarte Betriebsführung und Instandhaltung (Bendlin et al. 2021, S. 82)	97
Abb. 6.1: Implementierungsaufwand vs. Wertschöpfung für Vattenfalls Datenprodukte der höchsten Priorität	102
Abb. 6.2: Sankey-Diagramm für die höchstbewerteten Datenprodukte von Vattenfall.....	104
Abb. 6.3: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT01: <i>Is the turbine operating within the nominal range?</i>	105
Abb. 6.4: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT06: <i>Outliers in the timeseries</i>	106
Abb. 6.5: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT04: <i>Component failure rate</i>	107
Abb. 6.6: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT05: <i>Is the turbine operating in the correct IEC category?</i>	108
Abb. 6.7: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT12: <i>Lifetime extension of component</i>	109
Abb. 6.8: Implementierungsaufwand vs. Wertschöpfung für Ocean-Breeze-Datenprodukte der höchsten Priorität	111
Abb. 6.9: Sankey-Diagramm Gesamtübersicht Ocean Breeze.....	113
Abb. 6.10: Sankey-Diagramm Datenprodukt OBE05: <i>Wie verhalten sich 10-Minuten-Statistiken im Vergleich zu hochaufgelösten Daten?</i>	114
Abb. 6.11: Sankey-Diagramm Datenprodukt OBE01: <i>Wird der Generator in den nächsten Tagen/Wochen einen Fehler verursachen?</i>	115
Abb. 6.12: Sankey-Diagramm Datenprodukt OBE04: <i>Bestehen aktuell Fehlermuster an einer der Komponenten?</i>	116
Abb. 6.13: Sankey-Diagramm Datenprodukt OBE06: <i>Statistik zu Einsätzen</i>	117
Abb. 6.14: Implementierungsaufwand vs. Wertschöpfung für Deutsche Windtechnik's Datenprodukte der höchsten Priorität	119
Abb. 6.15: Sankey-Diagramm Gesamtübersicht Deutsche Windtechnik	120
Abb. 6.16: Sankey-Diagramm Datenprodukt DWT32: <i>Ist der Fehler schon häufiger aufgetreten?</i>	121
Abb. 6.17: Sankey-Diagramm Datenprodukt DWT58: <i>Performt die Windenergieanlage gemäß Nennleistungskurve?</i>	122

Abb. 6.18: Sankey-Diagramm Datenprodukt DWT67: <i>Um welchen Schaden handelt es sich?</i>	123
Abb. 6.19: Sankey-Diagramm Datenprodukt DWT05: <i>Welche Bauteile wurden überdurchschnittlich häufig verbraucht?</i>	124
Abb. 7.1: Beantwortung der Forschungsfragen	128
Abb. 7.2: Beispielhafte zukünftige Vereinfachung des Bewertungsmodells und der Skalierung	132
Abb. 7.3: Badewannenkurve vs. Premature Serial Failure (vgl. Stiesdal und Madsen 2005, S. 4 f.)	137
Abb. 7.4: ChatGPTs Antwort zum Einfluss von KI auf die Datenwertschöpfungskette von Organisationen (OpenAI 2023)	140

Tabellenverzeichnis

Tab. 2.1: Zusammenfassung Data-Mining-Prozesse (vgl. Foroughi und Luksch 2018, S. 10).....	20
Tab. 2.2: Ergebnisse der Literaturrecherche (Bendlin et al. 2024a, S. 5)	22
Tab. 2.3: Vergleich der Modelle der Datenwertschöpfungskette	23
Tab. 3.1: Haupt- und Unterbereiche der EN-Norm <i>Maintenance – Maintenance Key Performance Indicators</i> (vgl. CEN 2007, S. 7).....	40
Tab. 3.2: Exemplarische multivariater Entscheidungsunterstützungsmethoden (vgl. Zimmermann und Gutsche 1991, S. 27)	41
Tab. 3.3: Zielertrags-Matrix	45
Tab. 3.4: Elemente eines Geschäftsmodells (vgl. Osterwalder 2004, S. 47)	48
Tab. 3.5: Reduzierte Codierung als BMC-Input.....	50
Tab. 3.6: Angewandte Suchalgorithmen (vgl. Bendlin et al. 2024b, S. 82).....	51
Tab. 3.7: Klassifizierung der Canvas-Modelle.....	52
Tab. 3.8: Säulen der Datenwertschöpfungsketten-Ontologie.....	53
Tab. 3.9: Säulen und Elemente für die Datenwertschöpfungsketten-Ontologie	54
Tab. 3.10: Beschreibung des Wertversprechens des Elements	56
Tab. 3.11: Beschreibung des Elements Schlüsselressourcen	56
Tab. 3.12: Beschreibung der relevantesten Partner*innen des Elements	57
Tab. 3.13: Beschreibung der Schlüsselaktivitäten des Elements.....	57
Tab. 3.14: Beschreibung des Elements <i>Anwenderbericht</i>	58
Tab. 3.15: Beschreibung des Elements <i>Kanal</i>	58
Tab. 3.16: Beschreibung des Elements <i>Akzeptanzkriterien</i>	59
Tab. 3.17: Dimensionen von Datenqualität (vgl. Klein 2009, S. 22)	60
Tab. 3.18: Genutzte Variablen für die Bewertung der BVI-Bestandteile am Beispiel des BVIDEC (siehe Formel 3.9).....	63
Tab. 3.19: Kennzahlensystem für das Evaluationsmodell	64
Tab. 3.20: Beschreibung des Elements ROI_{DAQ}	65
Tab. 3.21: Beschreibung des Elements ROI_{DAGO}	65
Tab. 3.22: Beschreibung des Elements ROI_{DAMA}	66
Tab. 3.23: Beschreibung des Elements ROI_{DANA}	66
Tab. 3.24: Beschreibung des Elements ROI_{DEC}	67
Tab. 3.25: Beispielhafter Tabellenabschnitt mit multivariablen Auswahlmöglichkeiten.....	72
Tab. 6.1: Übersicht der untersuchten Vattenfall-Datenprodukte.....	103
Tab. 6.2: Übersicht der untersuchten Datenprodukte Ocean Breeze.....	112
Tab. 6.3: Übersicht der untersuchten Datenprodukte Deutsche Windtechnik	119
Tab. 7.1: Beispielhafte Kostenanteile der TCO (vgl. Verbeke et al. 2017, S. 356)	135

1 Einleitung

Häufig erkennen Organisationen den Wert von Daten für ihre Entscheidungsprozesse nicht. Im Ergebnis bleiben diese Werte ungenutzt „wie ein Rembrandt auf dem Dachboden“ (vgl. Verhulst 2020). Bevor Daten wertschöpfend in datengetriebene Entscheidungsprozesse eingesetzt werden können, müssen Anwendende von Datenanalyseergebnissen einen Bedarf definieren, den Data-Scientist*innen durch Datenaufbereitung und -analyse decken können. Zusammen können sie dazu beitragen, dass Entscheidungen durch Datenanalysen optimiert werden. Anwendende haben auf der einen Seite einen Überblick über die komplexen Entscheidungsprozesse, Herausforderungen und Fragestellungen in ihrer Anwendungsdomäne. Gleichwohl haben sie in der Regel kein Wissen darüber, wie Daten aufbereitet und analysiert werden können. Data-Scientist*innen verfügen auf der anderen Seite über das Wissen zu Datenanalyse und -aufbereitung, ihnen fehlt jedoch meist das Wissen über die Wertschöpfung ihrer Arbeit innerhalb der Anwendungsdomäne. Was beide Seiten zusammenbringt, sind Datenprodukte⁶, d. h. Fragestellungen, die durch Datenanalysen beantwortet werden können und einen Wert für die Anwendungsdomäne darstellen. Allerdings helfen sie nur bedingt, das Verständnis der spezifischen Herausforderungen innerhalb der *Data-Science*⁷ und der Anwendungsdomäne zu erhöhen. Um einen transparenten Austausch über diese Herausforderungen innerhalb der *Datenwertschöpfungskette* von der Datensammlung über die Aufbereitung bis hin zur Analyse und der daraus resultierenden Entscheidung zu ermöglichen, ist ein schnelles und einfaches Verständnis der Zusammenhänge notwendig. Visualisierungen unterstützen dabei, komplexe Zusammenhänge schnell zu begreifen, um datengetriebene Entscheidungsprozesse in Organisationen effektiv und effizient zu analysieren. Von zentraler Bedeutung ist es dabei, die Anforderungen sowohl von der Anwendungsdomäne als auch der Data-Science-Domäne zu formulieren. Diese bilden die Grundlage, um ein Evaluationsmodell zur Visualisierung und Analyse der Datenwertschöpfungskette zu definieren.

Die Hauptforschungsfrage lautet daher: *Wie kann eine Datenwertschöpfungskette visualisiert und analysiert werden?* Sie wird in drei Schritten durch Teilforschungsfragen beantwortet. Im ersten Schritt stehen die Anforderungen der Data-Scientist*innen im Mittelpunkt. So wird der Frage nachgegangen, wie eine Datenwertschöpfungskette aufgebaut sein muss, um Entscheidungsfindungen datengetriebener zu gestalten. Die Befragung der Anwendenden wird basierend auf einer Literaturrecherche durchgeführt. Um die Relevanz für die Anwendungsdomäne sicherzustellen, stehen im zweiten Schritt Interviews mit Anwendenden im Mittelpunkt. Dabei wird der Frage nachgegangen,

⁶ Datenprodukte werden in dieser Arbeit als geschäftsrelevante Probleme definiert, die mithilfe der Datenanalyse gelöst werden können.

⁷ Data-Science nutzt Methoden, Ideen, Prozesse und Modelle der Datenanalyse, um z. B. für Organisationen und Forschung einen Mehrwert aus Daten zu generieren.

welche Datenprodukte als relevante Fragestellungen in der Anwendungsdomäne existieren, die anhand von Datenanalysen beantwortet werden können. Durch die Einbindung der Anwendenden sollen eine höchstmögliche Relevanz und Akzeptanz für die Anwendungsdomäne erreicht werden. Im dritten Schritt wird ein Modell entwickelt, in das die Anforderungen der Domänen einfließen und visualisiert werden können, um eine Antwort auf die Frage *Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?* zu erarbeiten. Die Visualisierung im Modell schafft die Voraussetzungen für einen transparenten Austausch über die jeweiligen Bedürfnisse und ermöglicht der Data-Science und der Anwendungsdomäne, Optimierungen für datengetriebene Entscheidungsprozesse zu identifizieren und zu diskutieren.

1.1 Problemstellung

Ein effektiver Entscheidungsprozess, der Data-Science und datengestützte Ansätze einbezieht, kann Unternehmen erhebliche Vorteile bieten (vgl. Provost und Fawcett 2013, S. 2). Diese Vorteile zeigen sich insbesondere für projektorientierte Organisationen, die sich auf die Betreuung von Großprojekten spezialisiert haben. „Projekte sind ein zeitlich begrenztes Unterfangen zur Schaffung eines einzigartigen Produkts, einer Dienstleistung oder eines Ergebnisses“ (Project Management Institute 2013, S. 3). Der Begriff *Großprojekt* ist definiert als „Projekte, die aufgrund ihres Umfangs, ihrer Komplexität, der Dringlichkeit des Zeitplans oder der Beanspruchung der vorhandenen Ressourcen oder des Know-hows besonders anspruchsvoll sind“ (vgl. Morris und Hough 1987, S. 14). Ab einem Volumen von mehr als 100 Millionen Euro kann von einem Großprojekt gesprochen werden (vgl. Kostka und Fiedler 2016, S. 2). Komplexität ist unter anderem durch die eingesetzte Technologie oder das Zusammenspiel verschiedener beteiligter Akteur*innen und Disziplinen gegeben, was einen hohen Einfluss auf das Projektergebnis haben kann. So wiesen die ersten deutschen Offshore-Windparks aufgrund technologischer, finanzieller und politischer Herausforderungen eine Kostenüberschreitung von 22 % auf, die durch Lieferkettenprobleme und Verzögerungen beim Netzanschluss noch verschärft wurden (vgl. Kostka und Fiedler 2016, S. 181). Herausforderungen offenbarten sich etwa beim Bau des Berliner Flughafens oder der Elbphilharmonie in Hamburg; dabei kam es zu Verzögerungen und Kostenüberschreitungen (vgl. Kostka und Fiedler 2016, S. 3). Unvorhergesehene Ereignisse, fehlende oder unvollständige Daten sowie ein komplexes Projektumfeld erschweren die Entscheidungsfindung und können so Kosten erhöhen. Datengetriebene Entscheidungen basieren auf vorhandenen Daten, klar definierten Algorithmen oder Programmen. Dem stehen menschliche Entscheidungsprozesse gegenüber, die auf Bauchgefühl oder Erfahrung beruhen (vgl. McAfee und Brynjolfsson 2012). In der praktischen Anwendung ist bei der Entscheidungsfindung ein fließender Übergang zwischen beiden Bereichen vorhanden (vgl. Kruse 2017, S. 27). Die Intuition eines Anwendenden kann in einigen Fällen eine komplexe Datenauswertung unterstützen oder sogar ersetzen.

Was aber hindert Organisationen daran, den größtmöglichen Nutzen aus ihren Daten zu ziehen? Eine Herausforderung für datengetriebene Entscheidungen in der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks besteht darin, die Anforderungen unterschiedlicher Anwendenden zu erfüllen. So müssen etwa Vorgaben der kaufmännischen und technischen Betriebsführung (durch behördliche oder andere externe Auflagen) mit der IT-Infrastruktur und den möglichen Datenanalysen abgestimmt werden. Data-Science kann den Entscheidungsprozess durch datengestützte maschinelle Vorhersagen oder zusätzliche Analyseergebnisse verbessern. Die Schnittstelle zu den Anwendenden erweist sich dabei als besondere Herausforderung.

Laut dem *Global Survey on Data Driven Decision-Making in Businesses* von bi-survey gaben 58 % der befragten Organisationen an, dass mindestens die Hälfte ihrer typischen Geschäftsentscheidungen auf Grundlage von Instinkt oder Erfahrung und nicht auf Grundlage von Fakten oder datenbasiert getroffen wurde (vgl. BARC 2016). Sogenannte *HiPPOs* (*Highest Paid Person's Opinions*) idealisieren die eigene Intuition und lassen Datenanalysen häufig außer Acht (vgl. Anderson 2015).⁸

1.2 Anwendungsdomäne Onshore- und Offshore-Windparks

Großprojekte wie ein Offshore-Windpark zeichnen sich durch ihre Individualität, Einzigartigkeit und Komplexität aus (vgl. Sovacool und Enevoldsen 2015, S. 405 f.). Innerhalb des Projektlebenszyklus eines Onshore- und Offshore-Windparks hat die Betriebsführungs- und Instandhaltungsphase mit bis zu 25 Jahren den zeitlich größten Anteil (vgl. Hobohm et al. 2013, S. 25). Mithin findet sich innerhalb der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks ein großes Potenzial, Entscheidungsprozesse zu untersuchen und zu optimieren. Darüber hinaus macht diese Phase für Offshore-Windparks 30 % der Projektkosten aus (vgl. Dinwoodie et al. 2013, S. 158) und es stehen vielfältige Betriebsdaten zur Verfügung.

In den Anfangsphasen, etwa der Projektentwicklung und der Bauvorbereitung, sind wegen der Einzigartigkeit dieser Projekte (spezielle Seeboden- und Wetterverhältnisse sowie die Zusammensetzung der Komponenten) nur wenige oder lückenhafte Daten vorhanden. Diese Datenlage verbessert sich mit der Zeit durch Mess- und Sensordaten (unter anderem von Windenergieanlagen, Umspannstationen und Gründungsstrukturen), historische Wartungsaufzeichnungen sowie digitalisierte Wartungs- und Inspektionsprotokolle. All diese Daten fungieren als Basis für datengetriebene Entscheidungen innerhalb der Betriebsführung und Instandhaltung.

⁸ Laut einer weltweiten Gartner-Studie priorisieren CIOs Daten und Datenanalysen, allerdings haben 91 % der 196 untersuchten Organisationen in diesem Bereich noch keinen transformativen Reifegrad erreicht, obwohl ihnen dies einen Wettbewerbsvorteil verschaffen würde (vgl. Meulen und McCall 2018).

Mit dem Forschungsprojekt *WiSA Big Data* (01.12.2019–31.11.2023), in dem diese Arbeit verortet ist, wird das Ziel verfolgt, die Anforderungen an einen Software-Demonstrator (*Wind farm virtual Site Assistant (WiSA) for decision support using Big Data*) zu definieren und mithilfe eines Software-Prototyps umzusetzen. Die vorliegende Arbeit widmet sich datengetriebenen Entscheidungsprozessen in der Betriebsführung und Instandhaltung sowie der Analyse der Datenwertschöpfungskette. Dieser Aufgabenbereich bearbeitet und liefert iterativ und integrativ Ergebnisse sowie Beiträge zu verschiedenen Arbeitspaketen über die Projektlaufzeit.

Big Data bezeichnet Daten, die aufgrund der schieren Masse (Volume), der Geschwindigkeit (Velocity) und der Variabilität (Variety) Herausforderungen an das *Datenmanagement* stellen (vgl. Bitkom 2014, S. 12; Gross et al. 2016, S. 1). Dieser Grad an Komplexität erfordert methodische und technische Fähigkeiten der Data-Science. Da zahlreiche Rohdatensätze nicht direkt analysiert werden können, müssen Data-Analyst*innen einen hohen Aufwand für die visuelle Datenaufbereitung betreiben (vgl. Kenett und Redman 2019, S. 31). Daher ist es oftmals vonnöten, Datenprodukte in einem experimentellen und schrittweisen Ansatz zu bearbeiten (Weber 2014). Um diese Herausforderungen zu bewältigen, ist eine Methode erforderlich, die den Fluss von Daten innerhalb einer Organisation als wertvolle Ressource sichtbar macht. Dieser Prozess wird innerhalb der vorliegenden Arbeit als *Evaluationsmodell der Datenwertschöpfungskette* bezeichnet.

1.3 Motivation

Je fundierter die Informationsbasis ist, desto besser können Projekte geplant und Entscheidungen getroffen werden. So lassen sich mögliche Unsicherheiten wie Projektverzögerungen verringern oder vermeiden. Datengetriebene Entscheidungen können unterstützend wirken, wenn die Daten als wesentliche Ressource einer Datenwertschöpfungskette verstanden werden. Drei Hauptkomponenten dieser Wertschöpfungskette formen die Grundlage für datengetriebene Entscheidungen. Erstens bildet eine adäquate Anzahl an Datenquellen mit ausreichender Datenqualität die Grundlage für Datenanalysen. Zweitens müssen Datenmanagement, Data-Governance und Datenanalysen abgestimmt sein (etwa in Bezug auf vorhandene Ressourcen und Arbeitsabläufe). Damit können drittens Datenprodukte hervorgebracht werden, die in Organisationen Mehrwerte für Entscheidungen generieren. Eine verbesserte Datennutzung kann auf diese Weise zu einer besseren Entscheidungsgrundlage führen und Projektrisiken minimieren.

Das moderne Arbeitsumfeld hat sich durch Digitalisierung und die Verwendung moderner Kommunikationstechnik stark gewandelt. Diese Veränderung der Kommunikation hat gleichsam Einfluss auf Daten und datengetriebene Entscheidungen. Bereits 2015 wurde festgestellt, dass Organisationen einen Wandel von einem komplizierten (analogen) zu einem komplexen (digitalen) Entscheidungsumfeld durchlaufen (vgl. McChrystal et al., S. 57 ff.). Gleichzeitig entwickelten sich Software,

Kommunikationstechnik und Infrastruktur zum Datenmanagement weiter. Innerhalb der Mediennutzung im Arbeitsumfeld wurde früher vermehrt manuelle Dokumentenablage mit analogen Kommunikationskanälen verbunden, in denen wenige Sendende mit wenigen Adressierten in Kontakt treten konnten (Telefon, Brief, Fax). E-Mails, Chat-Services, digitale Dokumentation oder Online-Konferenzen ermöglichen es mittlerweile, eine deutlich komplexere und ortsunabhängigere Kommunikation durchzuführen, und erzeugen kontinuierlich zusätzliche Daten. Die COVID-19-Pandemie wirkte als Katalysator zur beschleunigten Digitalisierung von Dokumenten und Geschäftsabläufen (vgl. Almeida et al. 2020, S. 101). Data-Scientist*innen stehen vor der Herausforderung, Big Data zu verwalten und Anwendenden aus der Menge an Daten zeitnah entscheidungsrelevante Informationen zur Verfügung zu stellen. Daneben können Anwendende den Aufwand für Data-Scientist*innen nur schlecht einschätzen und den Wert ihrer Daten für Organisationen nur eingeschränkt bewerten.

Die Ergebnisse der vorliegenden Arbeit werden es der Industrie sowie Forschenden ermöglichen, die Datennutzung zur Entscheidungsfindung am Beispiel der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks zu bewerten. Im nächsten Schritt können Bestandteile der Datenwertschöpfungskette verbessert werden. So lassen sich Entscheidungsprozesse für Anwendende innerhalb der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks datengetriebener gestalten.

1.4 Zielsetzung

Der Beruf des*der Data-Scientist*in wurde bereits 2012 als „sexiest Job of the 21st century“ betitelt (Davenport und Patil 2012). Mehr als 10 Jahre später sind Anwendende immer noch keine Data-Scientist*innen. Gleichzeitig fällt es Data-Scientist*innen schwer, den Wert ihrer Analyseergebnisse für eine Anwendungsdomäne zu beurteilen. Artefakte dieser Arbeit bilden die Entwicklung eines durch eine Ontologie⁹ beschriebenen Evaluationsmodells zur Visualisierung von Datenwertschöpfungsketten. So soll die Kluft zwischen Anwendenden sowie Data-Scientist*innen auf beiden Seiten der Datenwertschöpfungskette überbrückt werden. Die Ontologie erklärt, wie eine Datenwertschöpfungskette aufgebaut, visualisiert und bewertet werden kann, und basiert auf der *Business-Model-Canvas(BMC)-Ontologie* (vgl. Osterwalder 2004, S. 104). Für Menschen und Organisationen, die aus Daten Werte generieren, können das Evaluationsmodell und die Datenwert-

⁹ In der Informatik kann eine Ontologie als ein Rahmenwerk verstanden werden, das eine kohärente Struktur und ein klar definiertes Lexikon bereitstellt, um den Austausch von Wissen innerhalb eines bestimmten Bereichs zu definieren und zu erleichtern (vgl. Noy und McGuinness 2001, S. 1).

schöpfungsketten-Ontologie als Leitfäden dienen, um Entwicklungsbereiche innerhalb ihrer Datenwertschöpfungskette zu identifizieren.

Die vorliegende Arbeit konzentriert sich auf datengetriebene Entscheidungsprozesse in der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks. Dabei wird darauf abgezielt, die nachfolgende Hauptforschungsfrage (HF) sowie die Teilforschungsfragen (TF) zu adressieren, die im Weiteren erläutert werden.

HF: Wie kann eine Datenwertschöpfungskette evaluiert, visualisiert und analysiert werden?

Diese Fragen können innerhalb des Forschungsprojekts *WiSA Big Data* (BMW i FKZ 03EE3016A) untersucht werden. In der Arbeit liegt der Fokus darauf, die Datenwertschöpfungskette der Industriepartnerschaften als Input für das Anforderungsprofil zu analysieren. Zu diesem Zweck wird eine Definition der Datenwertschöpfungskette aus einer Literaturrecherche als Grundlage für das Evaluationsmodell abgeleitet – bestehend aus einer Datenwertschöpfungsketten-Ontologie, einem *Bewertungsmodell* und einem *Kennzahlensystem* als Basis für die Visualisierung der Datenwertschöpfungskette. Die Ergebnisse werden iterativ mit Forschungs- und Industriepartnern aus *WiSA Big Data* besprochen und anhand von Fallbeispielen analysiert. Die Datenwertschöpfungsketten als Evaluationsergebnisse der Fallbeispiele werden als *Proof of Concept* durch einen in Python umgesetzten Software-Prototyp in Form von Sunburst- und Sankey-Diagrammen visualisiert.

TF1: Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?

Mithilfe einer Literaturrecherche werden verschiedene Definitionen und Methoden zur Erstellung von Datenwertschöpfungsketten identifiziert. Diese Definitionen werden im Rahmen von Interviews mit Expert*innen geprüft und optimiert. Anschließend werden der Begriff und alle für eine Analyse notwendigen Zusammenhänge in Form einer Datenwertschöpfungsketten-Ontologie abgeleitet. Um eine Datenwertschöpfungskette zu optimieren, müssen ihre einzelnen Bestandteile bewertbar, visualisierbar und analysierbar gestaltet werden.

TF2: Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?

Kern der Untersuchung sind Datenprodukte. Diese bilden Fragestellungen ab, die für die Anwendungsdomäne relevant sind und die anhand von Datenanalysen beantwortet werden können.

Durch QuestionStorming¹⁰ und Interviews mit Expert*innen sowie mit Anwendenden werden relevante Fragestellungen und Details für die Datenprodukte identifiziert. Damit eine Erforschung der datengetriebenen Entscheidungsprozesse ermöglicht wird, ist eine detaillierte Analyse der Datenprodukte und ihrer Einbindung in die Arbeitsabläufe von Betreiberfirmen notwendig. Diese Interviews mit Expert*innen werden mit den Industriepartnern Ocean Breeze, Deutsche Windtechnik, Iberdrola und Vattenfall im Forschungsprojekt *WiSA Big Data* durchgeführt. Die Industriepartner teilen sich in Betreiberfirmen und die Deutsche Windtechnik als ein individueller Serviceprovider (ISP)¹¹ auf. Alle Industriepartner weisen eine individuelle Betriebsführung und Instandhaltungsorganisation auf. Zusätzlich kann die Nutzung von Daten innerhalb der verschiedenen Hierarchieebenen einer Betriebsorganisation stark abweichen und historisch gewachsen sein. Aufgrund dieser individuellen Unterschiede wurde ein Rahmenwerk gesucht, das ausreichend flexibel ist, um bei variierenden Eingangsparametern vergleichbare Ergebnisse zu generieren. Die identifizierten Datenprodukte werden dann durch eine Nutzwertanalyse¹² priorisiert.

TF3: Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?

Basierend auf der Datenwertschöpfungsketten-Ontologie, dem Bewertungsmodell und dem Kennzahlensystem können die Bestandteile der Datenwertschöpfungskette visualisiert und analysiert werden. Zu diesen Bestandteilen zählen die Datenquellen, Data-Governance sowie Datenmanagement, Datenanalysemethoden, Visualisierung, Entscheidungsbeteiligte und Entscheidungen.

1.5 Einordnung der gewählten Forschungsmethoden in das Methodenspektrum der Wirtschaftsinformatik

Diese Arbeit verfolgt das Ziel, eine Datenwertschöpfungskette zu evaluieren, zu visualisieren und zu analysieren. Damit sollen die Anforderungen der Data-Science und der Anwendungsdomäne verbunden werden; diese Schnittstelle kann dem Bereich Wirtschaftsinformatik zugeordnet werden. Laut Wilde und Hess positioniert sich der Forschungsansatz der Wirtschaftsinformatik entlang zweier erkenntnistheoretischer (epistemologischer) Paradigmen zur Erweiterung des Wissensstands: Design Science und Behavioral Science (vgl. Wilde und Hess 2006, S. 3). Der Begriff der gestaltungs-

¹⁰ QuestionStorming beschreibt eine Kreativitätstechnik, bei der zu einem vorgegebenen Thema geeignete Fragen gesammelt werden – analog zu einem Brainstorming.

¹¹ Ein ISP bietet verschiedene individuelle Service-Dienstleistungen innerhalb einer Anwendungsdomäne an. Im Fall der Deutschen Windtechnik handelt es sich dabei um die Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks für Betreiber.

¹² Nutzwertanalysen bieten eine Möglichkeit, multivariate Handlungsalternativen durch bewertbare Kriterien zu analysieren und zu priorisieren (vgl. Kühnapfel 2019, S. 1).

orientierten Wirtschaftsinformatik (vgl. Österle et al. 2010, S. 662 ff.) wird für diese Arbeit zugunsten der Design Science Research aufgegeben.

- Die Behavioral Science befasst sich mit der Schaffung von Theorien zur Erklärung von menschlichem oder organisationalem Verhalten (vgl. Hevner et al. 2004, S. 75; Wilde und Hess 2006, S. 6).
- Die Design Science setzt sich damit auseinander, menschliche und organisationale Grenzen zu erweitern (vgl. Hevner et al. 2004, S. 75).

Diese Arbeit ist der Design Science zugeordnet, die danach strebt, „Modelle¹³, Methoden und Systeme“ zu schaffen oder zu evaluieren, um „nützliche IT-Lösungen“ zu generieren (Wilde und Hess 2007, S. 281). Der Forschungsrahmen wird von Geschäftsanforderungen mit den Unterpunkten *Menschen*, *Organisationen* und *Technologien* sowie vom anwendbaren Wissen beeinflusst (vgl. Hevner und Chatterjee 2010, S. 17). Basierend auf diesen Rahmenbedingungen lassen sich Theorien oder Artefakte entwickeln, die durch wissenschaftliche Methoden weiter verfeinert werden können (vgl. Hevner und Chatterjee 2010, S. 17). Die Ergebnisse der Forschung dienen der „Ergänzung der Wissensbasis“ und werden im Anwendungsgebiet eingesetzt (Hevner et al. 2004, S. 81). Dies wird durch die Visualisierung der Datenwertschöpfungskette und das Sichtbarmachen von Optimierungsmöglichkeiten erreicht.

Während die Problemrelevanz und die Forschungsfragen aus dem Forschungs- und Anwendungsgebiet der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks motiviert sind, werden Evaluationsmethoden der Wirtschaftsinformatik für die Methodologie genutzt. Einen besonderen Fokus innerhalb der Design Science haben „Modelle, Methoden oder Systeme“ (Wilde und Hess 2007, S. 281). Ziel dieser Arbeit ist es, die Forschungsfragen zu beantworten und dabei ein Modell zu erstellen, das die Evaluation der Datenwertschöpfungskette ermöglicht. Um dieses Ziel zu erreichen, wird als Evaluationsansatz eine Synthese mehrerer Methoden verwendet. Die gewählten Evaluationsmethoden können dem Methodenspektrum der Wirtschaftsinformatik nach Wilde und Hess zugeordnet werden (vgl. Wilde und Hess 2007, S. 282). Aufgrund der Komplexität des vorgeschlagenen Themas werden zur Beantwortung der Forschungsfragen mehrere Methoden kombiniert. Es können sechs Hauptforschungsmethoden der Wirtschaftsinformatik unterschieden werden: Kreativitätstechniken, Fallstudien, Prototyping, quantitative Querschnittsstudien, konzeptionelle deduktive Forschung sowie formale deduktive Forschung vgl. Wilde und Hess 2007, S. 283. Zusammen treten diese sechs Methoden in 91 % der untersuchten Studien zutage (vgl. Wilde und Hess 2007, S. 283). Auf dieser Basis kommt ein mehrstufiger Prozess aus Literaturrecherche und

¹³ Der Begriff des Modells lässt sich laut Wortursprung auf das lateinische Wort *modulus* als *Maß* und das italienische *modello* als *Muster*, *Vorbild* oder *Entwurf* zurückführen; so leitet sich die Funktion eines Modells als *Vorbild* oder *Nachbildung* ab (vgl. Gajewski 2004, S. 7; Springer 2017, S. 119).

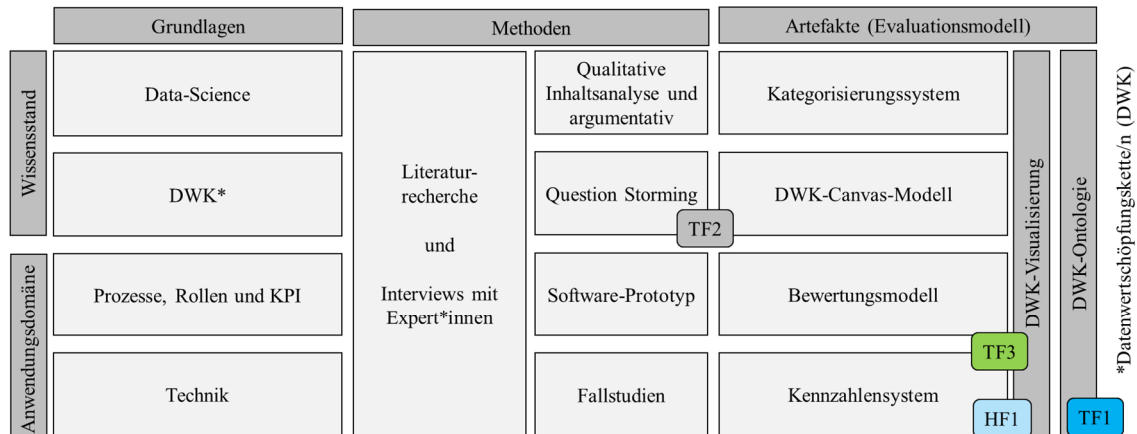
Interviews mit Expert*innen zur Erstellung eines Evaluationsmodells für eine Datenwertschöpfungskette zur Anwendung. Für diese Arbeit bot sich eine durch Literaturrecherchen angereicherte Aktionsforschung an. Aktionsforschung analysiert ein praktisches Problem iterativ gemeinsam mit Forschungspartnern (Data-Scientist*innen) und Anwendenden (Industriepartnern) durch verschiedene Methoden (vgl. Lewin 1946, S. 35). Im Forschungsprojekt *WiSA Big Data* standen Forschungspartner¹⁴ für die Data-Science-Methoden sowie Industriepartner¹⁵ aus der Anwendungsdomäne *Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks* für den fachlichen Austausch in Form von Interviews mit Expert*innen, Question Storming und Feedback zur Verfügung. Der fachliche Austausch wird durch verschiedene Phasen der Literaturrecherche begleitet.

1.6 Aufbau der Arbeit

Der Schwerpunkt dieser Arbeit besteht in der Entwicklung eines Evaluationsmodells für die Visualisierung und Analyse von Datenwertschöpfungsketten in der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks. Dabei ist es erforderlich, den theoretischen Hintergrund zu verstehen und geeignete Methoden für die Bewertung von Datenwertschöpfungsketten zu entwickeln. Um das Evaluationsmodell der Datenwertschöpfungskette zu erarbeiten, werden verschiedene wissenschaftliche Methoden kombiniert. In der anschließenden Untersuchung wird das Evaluationsmodell in Form von Fallbeispielen angewendet und ausgewertet. Abbildung 1.1 zeigt die schematische Darstellung des für diese Arbeit gewählten Vorgehens.

¹⁴ Carl von Ossietzky Universität Oldenburg (Abteilung Wirtschaftsinformatik/Very Large Business Applications), OFFIS e. V. Institut für Informatik, Universität Duisburg Essen, FORWIND und Fraunhofer IWES.

¹⁵ Vattenfall, Iberdrola, Ocean Breeze und Deutsche Windtechnik.



HF: Wie kann eine Datenwertschöpfungskette evaluiert, visualisiert und analysiert werden?

TF1: Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?

TF2: Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?

TF3: Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?

Abb. 1.1: Methodisches Vorgehen zur Beantwortung der Forschungsfragen

In dem folgenden Kapitel 2 werden zunächst die methodischen und begrifflichen Grundlagen der Data-Science definiert. Danach wird in Kapitel 3 das Evaluationsmodell zur Visualisierung der Datenwertschöpfungskette durch eine Literaturrecherche entwickelt. Dazu werden in einer ersten Literaturrecherche¹⁶ Übersichtsstudien zu datengetriebenen Entscheidungsprozessen untersucht. Diese werden durch eine qualitative Inhaltsanalyse ausgewertet und codiert (vgl. Mayring und Fenzl 2019, S. 636). Die Ergebnisse werden als Grundlage für die ersten Interviews mit Expert*innen (Anwendende) genutzt. Parallel dazu werden Vorarbeiten und Veröffentlichungen in relevanten Online-Datenbanken¹⁷ ausgewertet, um den Begriff der Datenwertschöpfungskette klarer zu definieren. Damit kann die erste Teilforschungsfrage (TF1) beantwortet werden: *Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?* Im nächsten Schritt wird aus dem Feedback ein erstes *Datenwertschöpfungsketten-Canvas* als verbesserte Anwenderschnittstelle entwickelt. Um die Evaluation der Fallbeispiele durch das Datenwertschöpfungsketten-Canvas-Modell zu vereinfachen, wird es im nächsten Schritt durch eine deduktive Literaturrecherche¹⁸ erweitert und finalisiert. Die Ergebnisse der Literaturrecherche werden durch eine qualitative Inhaltsanalyse (vgl. Mayring und Fenzl 2019, S. 639) ausgewertet.

¹⁶ Qualitative Querschnittsanalyse.

¹⁷ IEEE Xplore einschließlich IET, ACM Digitale Bibliothek, Springer Link, Science Direct, AISel und andere (MDPI, Wiley etc.).

¹⁸ Quantitative Querschnittsanalyse.

Im nächsten Schritt werden in Kapitel 4 Grundlagen zur Evaluation und Interviews mit Expert*innen beschrieben. Als Einführung in die Evaluation der Fallbeispiele werden anschließend die Grundlagen zur Evaluation und der Anwendungsdomäne *Betriebsführung und Instandhaltung von Onshore und Offshore-Windparks* in Kapitel 5 beschrieben. Danach werden die Fallbeispiele der Industriepartner als Anwendung des Evaluationsmodells in Kapitel 6 veranschaulicht. In den folgenden Interviews mit Expert*innen wird die zweite Teilforschungsfrage (TF2) beantwortet: *Welche relevante Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?* Dazu werden Datenprodukte durch die Kreativitätstechnik QuestionStorming identifiziert. Die Datenprodukte werden gemeinsam mit den Forschungs- und Industriepartnern priorisiert. So können die Industriepartner die relevantesten Datenprodukte anhand des Datenwertschöpfungsketten-Canvas mit Details versehen.

Die dritte Teilforschungsfrage (TF3) lautet: *Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?* Anhand einer weiteren Literaturrecherche werden ein *Kategorisierungssystem*, ein *Bewertungsmodell* und ein *Kennzahlensystem* entwickelt. Das Kategorisierungssystem dient der Kategorisierung von Datenprodukten und fungiert als Basis zur Bestimmung von Ambitionsleveln durch Interviews mit Expert*innen. Dafür werden die verschiedenen Kategorien von Anwendenden nach ihrer Relevanz bewertet. Das Kennzahlensystem teilt die Datenwertschöpfungskette in ihre Bestandteile auf und versieht diese Bestandteile mit Kennzahlen. Das Bewertungsmodell definiert Skalen, um die Datenwertschöpfungskette zu bewerten. Dadurch wird eine visuelle Umsetzung der Ergebnisse in Form eines Python-Prototypen als *Proof of Concept* (vgl. Wilde und Hess 2006, S. 6) möglich. Die Umsetzung des Prototyps gestattet die Bewertung der Visualisierung in Interviews mit Expert*innen, wodurch sich Optimierungen wie etwa die Einführung erweiterter Filteroptionen ableiten lassen.

Rückmeldungen aus diesen Fallbeispielen fließen in die Schlussbetrachtung in Kapitel 7 ein. Dort werden die Ergebnisse und Limitationen kritisch betrachtet, um theoretische und praktische Implikationen aufzuzeigen und so einen Ausblick auf zukünftige Forschungen zu geben.

2 Data-Science – Grundlagen

In diesem Kapitel werden Kernbegrifflichkeiten der Data-Science definiert, ein Fokus liegt hierbei auf der Datenwertschöpfung. Diese Definitionen bilden die Basis des Evaluationsmodells und der Interviews mit Expert*innen. Bei den Grundbegrifflichkeiten wird zuerst der Begriff Data-Science definiert und von gleichartigen Begrifflichkeiten abgegrenzt. Anschließend werden verschiedene Arten von Entscheidungsfindung beleuchtet, wobei es in diesem Kapitel um Entscheidungen auf Grundlage von Wissen von Anwendenden, datengestützten oder datengetriebenen Entscheidungen geht. Datengetriebene Entscheidungsprozesse bilden die Grundlage der Umsetzung des Evaluationsmodells und verkörpern einen Übergang zur Definition einer Datenwertschöpfungskette. Durch eine Literaturrecherche werden verschiedene Definitionen von Datenwertschöpfungsketten identifiziert und verglichen. Basierend auf diesen Grundlagen werden Optimierungspotenziale in Bezug auf methodische Expertise, Data-Governance und Datenqualität sowie die Rollen in Data-Science-Teams abgeleitet. Im Anschluss daran werden verschiedene Möglichkeiten diskutiert, wie Data-Science-Teams in Organisationen integriert werden können.

2.1 Begrifflichkeiten Data-Science

In der Gewinnung von Informationen aus Daten kann grob zwischen *BI*, *Advanced Analytics* oder einfach *Analytics* und Data-Science differenziert werden. Der Fachbereich Data-Science zur Auswertung von Big Data entwickelte sich aus der klassischen Statistik und dem Datenmanagement (vgl. Cielen et al. 2016, S. 1). Data-Science und das Berufsbild Data-Scientist*in gingen dabei aus dem Bedarf der Wirtschaft nach Methoden zur Auswertung umfangreicher Datenmengen hervor (vgl. Stockinger et al. 2016, S. 71). In der Vergangenheit wurden in Organisationen vor allem Auswertungen aus dem Bereich der *Business Intelligence (BI)* durchgeführt, um z. B. Waren-, Geldflüsse oder Kundensegmente zu analysieren und somit einen vergangenen Zustand oder einen Istzustand mithilfe historischer Daten zu beschreiben.

Business Intelligence: BI befasst sich hauptsächlich mit der Untersuchung historischer, strukturierter Daten und leitet daraus Wissen in Form von Reports oder Dashboards ab (vgl. Dietrich et al. 2015, S. 13; Gronau et al. 2016). Die klassische BI wertet historische Daten aus, um Geschehenes zu beschreiben und die Frage zu beantworten, was passiert ist (vgl. Gross et al. 2016, S. 2).

Neben BI werden Anwendungen der Data-Science genutzt, die auf Methoden wie Künstliche Intelligenz und Teilbereiche wie maschinelles Lernen und Deep Learning zurückgreifen (vgl. Kordon 2020, S. 16). Modelle, die auf maschinellem Lernen beruhen, sind selbstlernend, was sich von den ersten Modellen der Künstlichen Intelligenz unterscheidet, die fest codiert waren und auf Regeln beruhten (vgl. Brühl 2019, S. 5). Traditionelle analytische Anwendungen sind in den Bereichen BI

und Data-Mining zu finden; sie dienen als Bindeglied zwischen Technologie- und Anwendungsdomänen (vgl. Kordon 2020, S. 15).

Advanced Analytics oder Business Analytics: Es existieren verschiedene Begriffe für Advanced Analytics (vgl. Gross et al. 2016, S. 2 ff.), *Big Data Analytics* (vgl. Arabnia et al. 2020, S. 35), *Analytics* oder *Business Analytics* – durch sie wurde die Brücke zu geschäftlichen Anwendungen von Data-Science geschlagen (vgl. Chen et al. 2012, S. 1182). Analytics umfassen „Methoden zur möglichst automatisierten Erkennung und Nutzung von Mustern, Zusammenhängen und Bedeutungen“ in Daten (Bitkom 2014, S. 12). Dabei werden verschiedene Methoden und statistische Verfahren mit „Vorhersagemodellen, Optimierungsalgorithmen, Data Mining, Text- und Bildanalytik“ kombiniert (Bitkom 2014, S. 12).

Advanced Analytics bildet einen Oberbegriff für Datenanalysen, die sowohl die Vergangenheit als auch die Zukunft bewerten können. Während Zukunftsvorhersagen in der klassischen BI stark begrenzt sind und für ihre Erstellung vor allem strukturierte sowie semistrukturierte Daten verwendet werden, können mithilfe von Advanced Analytics zusätzlich unstrukturierte Daten analysiert werden (vgl. Gross et al. 2016, S. 2). Advanced Analytics oder Business Analytics lassen sich nicht klar von Data-Science abgrenzen (vgl. Haneke 2019, S. 1). Durch Techniken der Data-Science können BI-Analysen durch weitere Daten angereichert werden.¹⁹ Als Hauptmerkmal der Analytics identifiziert Haneke die deutliche Ausrichtung auf Organisationsziele der klassischen Analytics, die die BI um Methoden zur Auswertung von Big Data erweitert. Bei Data-Science dagegen liegt ein Fokus auf der für Organisationen gewinnbringenden Auswertung von Big Data. Dabei geht es neben einer besseren internen Datenauswertung auch um die Entwicklung neuer datenbasierter Geschäftsmodelle (vgl. Haneke 2019, S. 47). Innerhalb der Analytik kann zwischen BI und Data-Science unterschieden werden (vgl. Dietrich et al. 2015, S. 13). Business Analytics kann als *Pendant* der Data-Science innerhalb der BI verstanden werden; aufgrund der hohen Überschneidung kann Data-Science als Synonym für beides Verwendung finden (vgl. Haneke 2019, S. 1). Zum besseren Verständnis werden diese Begrifflichkeiten innerhalb dieser Arbeit vereinfachend unter Data-Science zusammengefasst (vgl. Haneke 2019, S. 1).

Data-Science: Data-Science ist eine Fachrichtung, die speziell auf die Auswertung großer Datenmengen zum Wissensgewinn ausgelegt ist. Diese Datenmengen werden unter dem Begriff *Big Data* zusammengefasst. Big Data zeichnet sich durch die sogenannten *drei V* aus: eine hohe Datenmenge (Volume), eine gewisse Datenvielfalt (Variety) und Geschwindigkeit (Velocity) der Datener-

¹⁹ Beispiele für diese Ergänzungen sind Echtzeitanalysen für den Online-Wertpapierhandel, weltweite Umsatzprognosen bei internationalen Konzernen (etwa IBM), dynamische Szenarioanalysen von Geschäftsszenarien, automatische Warenbestandsoptimierung, automatisierte Simulationen von Organisationsentwicklungen oder eine automatisierte Überwachung des Organisationsumfelds (vgl. Mehanna et al., S. 503 ff.).

zeugung (vgl. Bitkom 2014, S. 12; Gross et al. 2016, S. 1). Der Begriff wurde innerhalb der Forschung durch zusätzliche Vs erweitert. So kamen die Viskosität mit der Verwertbarkeit der Daten, der Value (Wert), die Variabilität (der Datentypen), die Verständlichkeit (und Qualität der Daten), die Visualisierungsanforderungen (an die Daten) und die Vertrauenswürdigkeit (Veracity) hinzu (vgl. Skiena 2017, S. 394 f.). Aufgrund dieser Komplexität von Big Data stoßen traditionelle Systeme wie Relational-Database-Management-Systeme an ihre Grenzen (vgl. Cielen et al. 2016, S. 1). Bei Big Data fallen etwa massive Datensätze als Produkt automatischer Protokollierungsprozesse an (vgl. Skiena 2017, S. 16). Diese Daten können von Data-Scientist*innen explorativ genutzt werden; im Gegensatz dazu steht bei der klassischen hypothesengesteuerten Wissenschaft ein von Wissenschaftler*innen entwickelter und beeinflussbarer Prozess der Datenerfassung und -auswertung (vgl. Skiena 2017, S. 3). Mithin haben moderne Data-Scientist*innen „wenig oder gar keine Kontrolle über den Erfassungsprozess“ und dementsprechend nur einen „vagen Anspruch, all diese Bits zu Geld zu machen“ (Skiena 2017, S. 393).

Data-Science umfasst die Analyse großer Mengen historischer und Echtzeitdaten, die strukturiert oder unstrukturiert vorliegen können. Basierend auf der Datenanalyse können Diagnosen (*Warum ist das passiert?*), Szenario-Simulationen (*Was wäre wenn ...?*) oder Vorhersagen (*Was wird als Nächstes passieren?*, *Was soll gemacht werden?*) erstellt werden (vgl. Dietrich et al. 2015, S. 13). Sobald die Frage, was unternommen werden soll, beantwortet werden kann, lassen sich die Analyseergebnisse zur Entscheidungsunterstützung oder zur Automatisierung von Ereignissen etwa durch eine Data-Factory verwenden (vgl. Gross et al. 2016, S. 4). Zur Data-Science gehören neben der Unterstützung datengetriebener Entscheidungsprozesse auch Produkt- und Marktanalysen, die Abwehr von Betrug (etwa im Versicherungswesen oder innerhalb der Revision) oder Aufgaben der BI oder Business Analytics (vgl. Patil 2019). Der Unterschied besteht hier in den verwendeten Mengen an Daten sowie den genutzten Data-Science-Methoden.

Um Techniken und Methoden der Data-Science nutzen zu können, sind verschiedene Voraussetzungen und Grundsätze zu erfüllen. Als erste Voraussetzung müssen ausreichend Daten in auswertbarer Form zur Verfügung stehen. Diese Big Data müssen in eine Infrastruktur (Data-Governance und Datenmanagement) eingebettet sein, die die Bearbeitung der Daten vor der Auswertung ermöglicht. Es kann dabei zwischen verschiedenen Grundsätzen der Data-Science differenziert werden (vgl. Provost und Fawcett 2013, S. 2).

Der erste Grundsatz besagt, dass die Gewinnung von Informationen aus Daten einem klaren Prozess folgen sollte. Wird einem klaren Ablauf gefolgt, ist die Wahrscheinlichkeit geringer, dass Fehler unterlaufen oder relevante Schritte ausgelassen werden.

Der zweite Grundsatz besteht darin, das Umfeld zu betrachten, in dem die Ergebnisse der Datenanalyse verwendet werden sollen. Dieser Kontext hilft bei der Entscheidung, welche Methode genutzt

werden kann, wie viel Ungewissheit akzeptabel ist und wie viel Wert die Analyse im Vergleich zu anderen Methoden hat.

Ein dritter Grundsatz bezieht sich darauf, dass die Analyseergebnisse so aufgeschlüsselt werden sollten, dass die Anwendenden den zugrunde liegenden Geschäftsbereich und das Geschäftsmodell besser verstehen können. Auf diese Weise kann die Antwort auf eine Kernfrage in mehrere Zwischenergebnisse unterteilt werden, die sich zur Lösung von Zwischenfragen verwenden lassen.

Ein weiterer Grundsatz ist die Suche nach Korrelationen in Daten, d. h. die Suche nach Daten, die in Beziehung mit anderen Daten stehen. Dies kann z. B. dazu genutzt werden, Unsicherheiten in der Datenanalyse zu verringern. Dieser Grundgedanke fungiert als Basis für zahlreiche statistische Analysen, Vorhersagemodelle und Data-Mining-Techniken.

Wie ähnlich sich Daten sind, wurde als nächster Grundsatz definiert. Eines der relevantesten Werkzeuge der Data-Science untersucht die Ähnlichkeit von Entitäten. „Es gibt viele Möglichkeiten, Ähnlichkeiten herauszufinden, und jedes Jahr werden es mehr“ (Provost und Fawcett 2013, S. 13).

Im letzten Grundsatz geht es darum, klare Kausalaussagen zu treffen, die sowohl sichtbare als auch verdeckte potenzielle Störfaktoren einschließen. Bei der Anwendung der Methoden ist es wichtig zu wissen, wie stark die Störfaktoren ins Gewicht fallen (vgl. Provost und Fawcett 2013, S. 14).

Als finale Definition für diese Arbeit wird eine Kombination aus verschiedenen Quellen herangezogen. Data-Science kann definiert werden als „Prinzipien, Prozesse und Techniken für die (automatische) Untersuchung von Daten“ (Provost und Fawcett 2013, S. 5). Die Verbesserung der Entscheidungsfindung als Zweck von Data-Science ist für Organisationen am relevantesten (vgl. Provost und Fawcett 2013, S. 5). Data-Science kann dabei als „Wertschöpfer aus Daten“ verstanden werden (Cielen et al. 2016, S. 1; Ozdemir und Kakade 2018, S. 4). Dabei kann der Aspekt des internen oder externen Nutzens als *Data-Science Product* ergänzt werden (vgl. Igual und Seguí 2017, S.-1). Zum besseren Verständnis wird der Begriff Data-Science Product zu *Datenprodukt* vereinfacht. So ergibt sich die für diese Arbeit gewählte Definition: Data-Science ist eine Sammlung von Methoden, Prinzipien, Prozessen und Modellen, um aus Datenprodukten (als geschäftsrelevante Fragestellungen, die mithilfe von Datenanalysen beantwortet werden können) Mehrwert für Organisationen zu generieren.

2.2 Datengetriebene Entscheidungsfindung

Innerhalb von Großprojekten werden Entscheidungen klassisch durch Anwendende getroffen. Anderson bezeichnet diese Form der Entscheidungsfindung als HiPPOs (Anderson 2015). Er unterstreicht, dass dabei häufig Daten ignoriert werden und stattdessen Gefühle, Intuition und Erfah-

rung im Vordergrund stehen. Vereinfacht kann im Projektverlauf von drei Stufen der Entscheidungsfindung gesprochen werden:

Entscheidungen auf Basis des Wissens von Anwendenden (Expert-Judgement): Hierbei werden Entscheidungen hauptsächlich basierend auf der Einschätzung von Anwendenden getroffen (vgl. Jifa und Lingling 2014, S. 815).

Datengestützte Entscheidungen (Data-informed): Hierbei werden Entscheidungen durch einfache Datenanalysen oder Simulationen unterstützt (vgl. Dinwoodie et al. 2013, S. 158).

Datengetriebene Entscheidungen (Data-driven): Hierbei bieten Datenanalysen die Basis für Entscheidungen (vgl. Provost und Fawcett 2013, S. 5).

Zu 1. Entscheidungen auf Basis des Wissens von Anwendenden: Innerhalb der Forschung befasst sich die Entscheidungstheorie mit der menschlichen Entscheidungsfindung. Dabei lassen sich drei Teildisziplinen unterscheiden (siehe Abb. 2.1): die normative, die deskriptive und die präskriptive Entscheidungstheorie (vgl. Nitzsch und Methling 2019, S. 1).

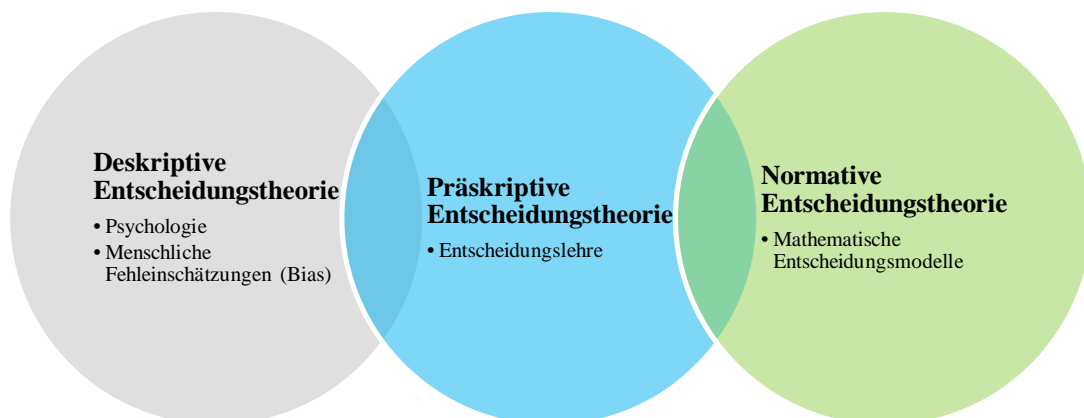


Abb. 2.1: Bereiche der Entscheidungstheorie (vgl. Nitzsch und Methling 2019, S. 1)

Die Art, wie Menschen Entscheidungen treffen, ist entweder kognitiv (basierend auf Erlerntem) oder verhaltensorientiert (basierend auf Umwelteinflüssen) (vgl. Lammers 2006, S. 1040).

Die normative Entscheidungstheorie kann zurückgehend auf Daniel Bernoulli (1700–1782) als Ursprung der Entscheidungstheorie betrachtet werden (vgl. Nitzsch und Methling 2019, S. 1). In diesem Bereich wird ermittelt, wie wahrscheinlich das Ergebnis einer Entscheidung angesichts von Risiken und Unsicherheiten ist (vgl. Buchanan und O’Connell 2006). Bei der statistischen Entscheidungstheorie geht es darum, „zielgerichtete Entscheidungen unter Unsicherheit mit begrenzten Ressourcen zu treffen“ (Longford 2013, S. 2). Bei der präskriptiven Entscheidungstheorie wird auf ebendiese Fehleinschätzungen (Biases) reagiert und die normative Entscheidungstheorie um individuelle Entscheidungspräferenzen ergänzt (vgl. Nitzsch und Methling 2019, S. 2).

Zu 2. Datengestützte Entscheidungen: Maschinen treffen datenbasierte Entscheidungen; dem stehen Entscheidungen gegenüber, die auf Intuition oder Erfahrung beruhen (vgl. McAfee und Brynjolfsson 2012, S. 63). Tatsächlich existiert bei der Entscheidungsfindung ein fließender Übergang zwischen beiden Bereichen. Gelegentlich kann die Intuition oder Einschätzung eines*einer Anwendenden Datenanalysen ersetzen. Oftmals beeinträchtigen menschliche Fehleinschätzungen allerdings auch große Projekte (vgl. Kostka und Fiedler 2016, S. 181). Daher repräsentiert eine solide Datenbasis den Ursprung jeder fundierten Entscheidung. Während indes die Datenbasis als Entscheidungsgrundlage mit dem Projektverlauf steigt, sinkt der Einfluss von Entscheidungen auf die Projektunsicherheiten. Dementsprechend muss, bis die Datengrundlage ausreichend gestiegen ist, auf Urteile von Anwendenden zurückgegriffen werden. Im Rahmen der Inbetriebnahme und Wartung von Onshore- und Offshore-Windparks müssen komplexe Entscheidungsalternativen in einem multivariaten Umfeld bewertet werden. Diese Bewertung kann menschlich oder maschinell durch stochastische Methoden zur Datenanalyse (z. B. Messdaten aus früheren Projekten) sowie die Simulation von Modelldaten generiert werden. Dieses Forschungsfeld wurde für Onshore- und Offshore-Windparks hinreichend untersucht. Die Ergebnisse wurden auf der Konferenz *Betriebliche Umweltinformationssysteme (BUIS-Tage) 2018* veröffentlicht. Insgesamt konnten 39 verschiedene Simulationsmodelle zur Datenanalyse und Entscheidungsunterstützung in diesem Bereich identifiziert werden (vgl. Bendlin et al. 2019, S. 598; Seyr und Muskulus 2019, S. 279 ff.). Auffällig an diesen Simulationswerkzeugen ist, dass sie in erster Linie individuelle Entscheidungsprobleme lösen. Mehrdimensionale Entscheidungsprozesse werden durch eine vereinfachte Hierarchisierung der Variablen gelöst. So ist beispielsweise das Wetter als limitierender Faktor für die Bewertung einer gesamten Logistikstrategie entscheidend. Traditionelle Modelle der Entscheidungsfindung unter Unsicherheit setzen perfekte Information voraus, d. h. genaue Werte für die Systemparameter und spezifische Wahrscheinlichkeitsverteilungen für die Zufallsvariablen (vgl. Bertsimas und Thiele 2006, S. 95). Solch präzises Wissen ist allerdings in der Praxis selten verfügbar und eine Strategie, die auf fehlerhaften Eingaben beruht, könnte sich bei der Umsetzung als nicht durchführbar herausstellen oder eine schlechte Leistung aufweisen (vgl. Bertsimas und Thiele 2006, S. 95).

Zu 3. Datengetriebene Entscheidungen: Datenverarbeitung und -analyse verwandeln Daten in kontextualisierte Informationen, Wissen und Weisheit (vgl. Haneke 2019, S. 22). Weisheit als letzte Stufe beschreibt, wann und weshalb das Wissen genutzt werden sollte (vgl. Jifa und Lingling 2014, S. 815). Um eine Strategie für die Verbesserung der Datenwertschöpfungskette abzuleiten, wurde die *Data, Information, Knowledge und Wisdom (DIKW)-Pyramide* (vgl. Ackoff 1989, S. 3) um Kernfragen sowie Zielsetzungen aus dem *analytischen Reifegradmodell* (vgl. Taylor 2013) erweitert (siehe Abb. 2.2). Durch diese Erweiterung können die Stufen der Pyramide mit der Zielsetzung der Analytik kombiniert werden. Der analytische Reifegrad reicht von einer deskriptiven Betrachtung

der Daten über eine diagnostische Auswertung bis hin zu prädiktiven Vorhersagen oder sogar der Automatisierung von Arbeitsabläufen (vgl. Gross et al. 2016, S. 4).

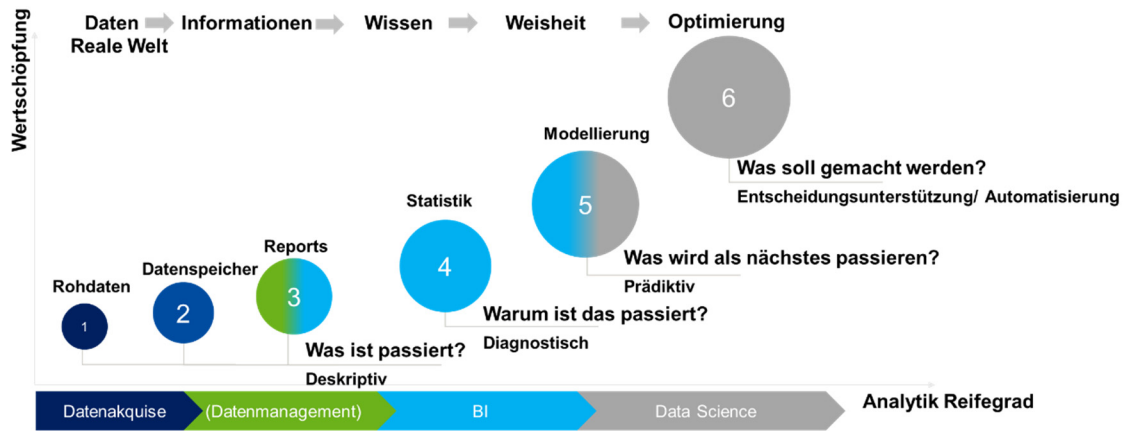


Abb. 2.2: Analytischer Reifegrad (vgl. Gross et al. 2016, S. 1; Taylor 2013)

Jede der Zielsetzungen bedarf verschiedener Grundvoraussetzungen, etwa Datenakquise, Data-Governance und Datenmanagement. Erst dadurch wird eine Auswertung der Daten über BI oder Data-Science möglich. Damit sind Grundvoraussetzungen zum Erreichen der nächsten Pyramidenstufe definiert. Die DIKW-Pyramide (siehe Abb. 2.3) wurde als Denkmodell zur Darstellung der Zusammenhänge der Grundbegrifflichkeiten Daten, Informationen, Wissen und Weisheit (aus Daten) erstellt (vgl. Ackoff 1989, S. 170 ff.). In zahlreichen Veröffentlichungen wird dabei eine vereinfachte vierstufige Pyramide gezeigt, bei der die reale Welt oder der*die Datenlieferant*in ausgeblendet ist (vgl. Bernstein 2009, S. 69; Haneke 2019, S. 22; Jifa und Lingling 2014, S. 815). Da innerhalb dieser Arbeit die gesamte Datenwertschöpfung betrachtet werden soll, wurde die fünfstufige Darstellung gewählt; sie umfasst die reale Welt (vgl. Haneke 2019, S. 22).



Abb. 2.3: DIKW-Pyramide (vgl. Ackoff 1999, S. 170 ff.)

Eine Kritik an der DIKW-Pyramide bezieht sich auf die starke Vereinfachung der Hierarchieebenen und ihrer Zusammenhänge (vgl. Bernstein 2009, S. 69). Aus diesem Grund ist eine detailliertere Definition der Datenwertschöpfung vonnöten.

Zur Beschreibung der Anforderungen für die Durchführung von Data-Science-Projekten wurde in Abb. 2.4 ein DIKW-Zwiebelschalenmodell zur Visualisierung der Voraussetzungen für die Imple-

mentierung von Data-Science entwickelt. Dieses Modell ist zur Erklärung der groben Zusammenhänge erforderlich. Eine Limitierung ergibt sich daraus, dass die Abgrenzung der Bereiche BI und Data-Science aufgrund ihrer stetigen Erweiterung nicht trennscharf ist (vgl. Haneke 2019, S. 1).

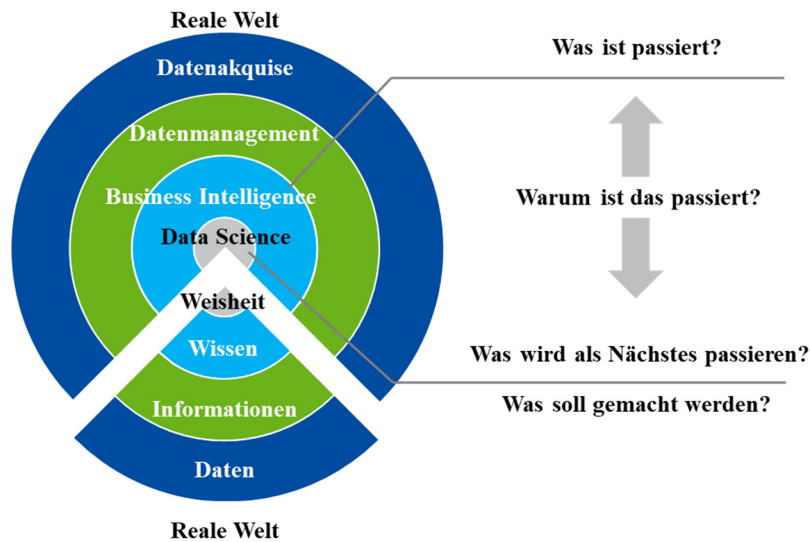


Abb. 2.4: Voraussetzungen für die Implementierung von Data-Science

Dieses Modell unterstützt dabei, Optimierungsmöglichkeiten aufzuzeigen. Ist für die Entscheidungsfindung kein Zugriff auf Sensor- oder andere Rohdaten vorhanden, muss die Datenakquise verbessert werden. Sobald ein Datenmanagement, etwa durch ein Data-Warehouse, etabliert ist, sind einfache statistische Auswertungen möglich. Diese Auswertungen werden hier vereinfachend unter dem Begriff *Business Intelligence* (BI) zusammengefasst.

Die optimale Nutzung von BI und Data-Science erfordert eine Optimierung der gesamten Datenwertschöpfungskette mit expliziten Anforderungen an Data-Governance und Datenmanagement, z. B. die Einführung oder Nutzung von einem Data-Warehouse, einem Data-Lake oder einer Mischung aus beidem (vgl. Baars und Marschall 2019, S. 3). Um diese Daten auszuwerten, werden im Rahmen von Data-Science komplexere Methoden herangezogen, die weit über die klassische BI hinausgehen. Für die Bewertung der Datenakquise spielt die Genauigkeit der Datenerhebung eine bedeutende Rolle. Diese kann z. B. durch physikalische Begrenzungen der Sensoren, durch deren fehlerhafte Platzierung oder durch Umweltbedingungen beeinflusst werden (vgl. Klein 2009, S. 12).

Wird die Datenanalyse bei der Entscheidungsfindung in Organisationen eingesetzt, resultiert daraus ein bedeutender Mehrwert für Projekte. Datengestützte Entscheidungsprozesse sorgen dafür, dass Entscheidungen auf Grundlage von Daten und nicht von Intuition getroffen werden (vgl. Foroughi und Luksch 2018, S. 3). Die essenzielle Voraussetzung bildet die Verwendung vollständiger und hochwertiger Daten (vgl. Bosnjak et al. 2009, S. 1; Nadali et al. 2011, S. 163). Im nächsten Schritt müssen die Daten angemessen ausgewertet werden, z. B. durch Korrelation und Mustererkennung (vgl. Foroughi und Luksch 2018, S. 5). Damit ist die Grundlage für die Analyse der Daten geschaffen.

Die Verbesserung von Datenanalysen in Organisationen wurde durch zahlreiche theoretische und empirische Methoden untersucht. Tabelle 2.1 enthält eine Zusammenfassung der identifizierten Data-Mining-Prozesse (vgl. Foroughi und Luksch 2018, S. 10).

KDD*-Prozess	CRISP-DM**	FMDS***	TDSP****
-	Business-Understanding	Business-Understanding	Business-Understanding
-	-	Analytic Approach	
-	-	Data-Requirements	
Selection	Data-Understanding	Data-Collection	Data-Acquisition and -Understanding
Pre-Processing		Data-Understanding	
Transformation	Data-Preparation	Data-Preparation	
Data-Mining	Modelling	Modelling	Modelling
Interpretation/ Evaluation	Evaluation	Evaluation	
-	Deployment	Deployment	Deployment
-	-	Feedback	Customer-Acceptance
*Knowledge Discovery in Databases **Cross-Industry Standard Process for Data-Mining ***Foundational Methodology for Data-Science ****Team Data-Science Process			

Tab. 2.1: Zusammenfassung Data-Mining-Prozesse (vgl. Foroughi und Luksch 2018, S. 10)

Die vorgestellten Prozesse haben gemeinsam, dass sie aus iterativen Phasen der Problemdefinition, wie Datensammlung, Datenmodellierung und Datenproduktentwicklung, bestehen (mit Ausnahme der Knowledge Discovery in Databases-Methode).²⁰ Diese Methode verfügt nicht über eine Geschäftsverständnisphase, in der die Aufgabenstellung in der Anwendungsdomäne geklärt wird. Darüber hinaus fehlt eine Bereitstellungsphase, in der ein System zur Entwicklung eines Datenprodukts geliefert wird.

Der *Cross-Industry Standard Process for Data Mining* (CRISP-DM) hat sich weltweit branchenübergreifend etabliert und ist mit Abstand die meistverwendete Methode für Data-Mining-Projekte (vgl. Foroughi und Luksch 2018, S. 6). Der CRISP-DM-Prozess wurde 1996 von SPSS, Teradata,

²⁰ Neben den bereits vorgestellten Prozessen bestehen auch Alternativen, z. B. der *Sample, Explore, Modify Model and Asses*-Prozess. Ursprünglich wurde dieser vom SAS Institut entwickelt und ist daher mit der Software *SAS Enterprise Miner* verknüpft. Aufgrund dieser Limitierung wird er hier nicht weiter berücksichtigt (vgl. Azevedo und Santos 2008, S. 184).

NCR, Daimler und OHRA eingeführt (vgl. Practical Application Company 2000, S. 1). Es handelt sich um einen Zyklus aus sechs Phasen, deren Reihenfolge nicht festgelegt ist, sondern flexibel an den Bedarf des Vorhabens angepasst werden kann (vgl. IBM 2016, S. 1). CRISP-DM ist logisch und intuitiv aufgebaut und bietet auch für anspruchsvolle Projekte ein hohes Maß an Qualität und Effizienz (vgl. Foroughi und Luksch 2018, S. 7). Das Modell enthält eine ausführliche Übersicht über die typischen Phasen eines Projekts und die Aufgaben in jeder Phase sowie Erläuterungen zu den Verhältnissen zwischen den Aufgaben (vgl. IBM 2016, S. 1). Es finden sich zahlreiche Studien, die sich mit dieser Methode befassen haben. Ein für den Erfolg von Projekten entscheidender Faktor besteht darin, dass CRISP-DM unabhängig von den Data-Mining-Tools durchgeführt werden kann (vgl. Foroughi und Luksch 2018, S. 7; Mariscal et al. 2010, S. 138). Die sechs Phasen umfassen das Geschäftsverständnis (*Business-Understanding*), das Datenverständnis (*Data-Understanding*), die Datenvorbereitung (*Data-Preparation*), die Modellierung (*Modeling*), die Evaluierung (*Evaluation*) sowie die Bereitstellung (*Deployment*) (vgl. Chapman et al. 2000, S. 13) (siehe Abb. 2.5).




Abb. 2.5: Cross-Industry Standard Process for Data Mining (CRISP-DM) (vgl. Foroughi und Luksch 2018, S. 6)

CRISP-DM fehlt es an analytischen Methoden und Rückkopplungsschleifen zur Verbesserung von Methoden und Modellen (vgl. Foroughi und Luksch 2018, S. 11). Dies könnte entscheidend sein, wenn Daten unstrukturiert oder semistrukturiert vorliegen (vgl. Foroughi und Luksch 2018, S. 11). Es stellt sich ebenso die Frage, wie leicht CRISP-DM zur Kommunikation mit verschiedenen Interessenvertreter*innen genutzt werden kann (vgl. Wirth und Hipp 2000, S. 9). Dieser Aspekt wurde von den ursprünglichen Entwicklern des CRISP-DM als besonders herausfordernd hervorgehoben (vgl. Wirth und Hipp 2000, S. 9). Dennoch eignet sich CRISP-DM als Rahmenwerk für

Befragungen (vgl. Wirth und Hipp 2000, S. 1). Gleichwohl stellt sich auch nach erfolgreicher Implementierung von CRISP-DM zur Unterstützung von Datenanalysen die Frage, wie viel effizienter Entscheidungen getroffen werden und wie viel Potenzial für Optimierungen bleibt. Daher kann auch CRISP-DM nicht zur vollständigen Analyse der Datenwertschöpfungskette genutzt werden und ist für diese Arbeit zu vereinfachen.

2.3 Datenwertschöpfungsketten

Alternativ zu CRISP-DM existieren verschiedene Datenwertschöpfungsketten-Modelle für Big Data (vgl. Cavanillas et al. 2016, S. 18; Hay et al. 2017, S. 4; Miller und Mork 2013, S. 3). In dieser Arbeit wurde ein Suchalgorithmus entwickelt und auf Online-Datenbanken angewendet, um einen Überblick über alternative Modelle zu erhalten (siehe Tab. 2.2) (vgl. Hay et al. 2017, S. 4). Die Quellen wurden dann in A- und B-Quellen gruppiert (vgl. Prexl 2019, S. 32 ff.).

Online-Datenbank	Gesamt [Alle]	Relevant [B]	Relevant [A]	Suchalgorithmus
IEEE Xplore including IET	34	17	3	<i>data value chain</i>
ACM Digital Library	28	3	1	<i>data value chain</i>
Springer Link	201	34	12	All: <i>data value chain</i> within Computer Science
Science Direct	144	23	8	<i>data value chain</i>
AISeL ²¹	51	17	3	<i>data value chain</i>
Wiley Online Library	47	8	0	<i>data value chain</i>
Total	505	102	27	-

Tab. 2.2: Ergebnisse der Literaturrecherche (Bendlin et al. 2023, S. 5)

Von den 27 A-Quellen, die für diese Arbeit verwendet wurden, waren 21 öffentlich zugänglich und wurden als Basis für Tab. 2.3 herangezogen und miteinander verglichen. Für diese Arbeit können die *IoT-enabled product visual analytics value chain* (vgl. Emmanouilidis et al. 2018, S. 437) und die *data value chain* (vgl. Åkerman et al. 2018, S. 414) vernachlässigt werden, da sie lediglich für bestimmte Anwendungsfälle wie die vorausschauende Wartung relevant sind. Zahlreiche Wissen-

²¹ AISeL (Verband für Informationssysteme eLibrary).

schaftler*innen haben sich auf die Modelle von Curry et al.²² sowie von Miller und Mork²³ bezogen (vgl. Dinter und Kollwitz 2016, S. 6; Faroukhi et al. 2020, S. 14; Kaiser et al. 2021, S. 8). Diese Modelle sind etablierter als verwandte Modelle wie die *Big Data Value Chain* (vgl. Faroukhi et al. 2020, S. 16) oder einfachere Modelle (vgl. Beyan et al. 2016, S. 590; Mörth et al. 2020, S. 3), die aus diesem Grund nicht in der Übersicht berücksichtigt sind.

CRISP-DM	BMC	Datenwert-schöpfungskette (für Big Data)	Big-Data-Wert-schöpfungskette	Datenwert-schöpfungskette
Geschäfts-verständnis	Wichtigste Aktivitäten Wichtige Partner*innen Kundenbeziehungen Segmente von Kund*innen	k. A.	k. A.	Entscheidung
Datenverständnis	Wichtige Ressourcen Wichtigste Aktivitäten Wichtige Partner*innen	Entdeckung von Daten: Sammeln und annotieren	Datenerfassung	Datenakquise
Vorbereitung der Daten	Wichtige Ressourcen Wichtigste Aktivitäten Wichtige Partner*innen	Entdeckung von Daten: Vorbereiten Organisieren Integration von Daten	Speicherung von Daten Datenmanagement	Datenmanagement Data-Governance
Modellierung	Wichtige Ressourcen Wichtigste Aktivitäten Wichtige Partner*innen	Datenverwertung: Analyse Visualisierung	Analyse der Daten	Datenanalyse
Bewertung	Nutzenversprechen Kostenstruktur Einnahmeströme	k. A.	k. A.	Datenanalyse
Einsatz	Kanäle	Datenverwertung: Entscheidungen treffen	Datenverwendung	Entscheidung

Tab. 2.3: Vergleich der Modelle der Datenwertschöpfungskette

Eine Wertschöpfungskette ist ein „zeitlich nacheinander“ ablaufender Fluss von Vorgängen durch verschiedene „Leistungsstellen“, die zu einer Wertschöpfung führen (Gudehus 2010, S. 24). Abbildung 2.6 zeigt eine schematische logistische Wertschöpfungskette.

²² Das Modell von Curry umfasst die Phasen Datenbeschaffung, Datenanalyse, Datenaufbereitung, Datenspeicherung und Datennutzung (vgl. Cavanillas et al. 2016, S. 32).

²³ Miller und Mork unterscheiden dabei drei Hauptphasen: Data Discovery, Data-Integration und Data-Exploitation (vgl. Miller und Mork 2013, S. 3).




Abb. 2.6: Wertschöpfungskette (vgl. Blume 2020, S. 10; Gudehus 2010, S. 24)

Analog zur logistischen Wertschöpfungskette besitzen auch Datenprodukte definierbare Prozessschritte mit klaren In- und Outputs. Dieser Prozess ist vergleichbar mit der Förderung und Raffinierung von Öl (vgl. Kordon 2020, S. 40 ff.). Analog dazu beginnt der Prozess mit der Ölförderung oder Datenakquise, gefolgt von der Lagerung oder dem Datenmanagement sowie der eigentlichen Raffinierung durch Datenanalyse und von der Nutzung zur Entscheidungsunterstützung in Form eines Datenprodukts.

In Abb. 2.7 ist die Datenwertschöpfungskette schematisch veranschaulicht. Für sie bilden angemessen vorhandene Daten die Grundlage. Zweitens gibt Data-Governance Verfahren und Verantwortlichkeiten vor, um die Datenqualität zu gewährleisten. Das Datenmanagement macht die Daten zugänglich. In der vierten Stufe wird die Datenanalyse durchgeführt. In der fünften Stufe muss die Datenanalyse Datenprodukte liefern, die die Geschäftsentscheidungen verbessern.




Abb. 2.7: Teile der Datenwertschöpfungskette

Das Ergebnis ist ein flexibles und anpassungsfähiges Modell der Datenwertschöpfungskette. Wie die bisherige Untersuchung zeigt, finden sich zahlreiche Ansätze zur Erklärung der Wertschöpfung aus Daten. Um ein universelles Modell abzuleiten, muss die Lösung an das Ziel der Bewertung und die Zielgruppen (z. B. Datenwissenschaftler*innen und Anwendende) angepasst werden können. Dies soll in Form einer Datenwertschöpfungsketten-Ontologie beschrieben werden.

Datenakquise: Um aus der realen Welt Informationen zu gewinnen, müssen Daten erfasst werden. In der Regel werden Sensoren verwendet, die physikalische Messgrößen aufnehmen. Ein Beispiel eines typischen Datenakquise-Systems ist in Abb. 2.8 ersichtlich. Vereinfacht soll hier unter Datenakquise neben klassischer Sensorik auch die manuelle Erfassung von Dokumenten oder Protokollen verstanden werden.

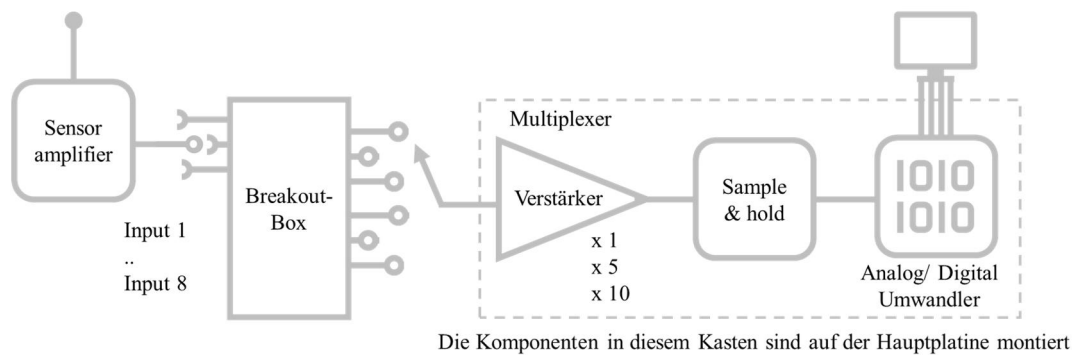


Abb. 2.8: Typisches Datenakquise-System (vgl. Young 2001, S. 10)

Data-Governance: Die Festlegung von Rollen und Methoden für die Datenverwaltung in Organisationen erfordert ein gemeinsames Wissen über Ontologien und Datenmanagement. Dabei beinhaltet Data-Governance die Entwicklung und Durchsetzung von Datenmanagementregeln sowie -standards (vgl. Mahanti 2021, S. 1).

Datenmanagement: Datenmanagement umfasst alle „Techniken, Methoden und Fallstudien, um Datenerfassung und Datenintegration zu verbessern“ (Koltsidopoulos Papatzimos 2019, S. V). Unter Datenmanagement fallen sämtliche Aktivitäten entlang des Datenlebenszyklus, etwa die Schaffung und Erhaltung einer Infrastruktur, um Daten als wertvolle Ressource zu sammeln und für eine zielgerichtete Datenauswertung zur Verfügung zu stellen (vgl. Kampakis 2020, S. 23). Es kann hierbei beispielhaft zwischen einem klassischen Data-Warehouse für BI-Anwendungen und einem Data-Lake für Big-Data-Anwendungen unterschieden werden (vgl. Baars und Marschall 2019, S. 2). Allerdings erhöht die erwähnte Datenversorgung die Effektivität der Entscheidungsfindung nur dann, wenn die gesamte Datenwertschöpfungskette und die Data-Governance-Aktivitäten berücksichtigt werden (vgl. Baars und Marschall 2019, S. 4).

Datenanalyse (Datenprodukte): Zur Verbesserung der Entscheidungsfindung durch Datenprodukte nutzt Data-Science verschiedene Methoden, um in Daten Muster zu erkennen und daraus Erkenntnisse zu gewinnen. Dabei kann grob zwischen traditionellen Methoden und maschinellem Lernen differenziert werden (vgl. Dobрева 2018).

Entscheidung: Die Datenanalyse ersetzt die Intuition bei der datengetriebenen Entscheidungsfindung (vgl. Provost und Fawcett 2013, S. 5). Um datengetriebene Entscheidungen in Form einer Datenwertschöpfungskette zu ermöglichen, muss der Zusammenhang von Daten und Entscheidungen verstanden werden.

2.4 Rahmenbedingungen von Datenwertschöpfungsketten

Diese Arbeit soll Organisationen und Forschung bei der Analyse und Anpassung von Datenwertschöpfungsketten unterstützen. So können Fehleinschätzungen minimiert und Betriebsausgaben für Onshore- und Offshore-Windparks optimiert werden. In Data-Science-Projekten kann es zu verschiedenen Herausforderungen kommen: Limitierung der Methoden, Grenzen der Infrastruktur, fehlende Kenntnisse, Erfahrungen oder Kompetenzen sowie begrenzte Modellierungserfahrung (vgl. Kordon 2020, S. 29). Dabei ist das Kompetenzprofil für ein starkes Data-Science-Team ausschlaggebend (vgl. Wyss 2019). Die Ergebnisse können dabei nur an der vorhandenen Datenqualität gemessen werden, die als bedeutender Input-Faktor fungiert (vgl. Seiner 2014, S. 65). Zusammenfassend lassen sich folgende Rahmenbedingungen identifizieren, die nachstehend beleuchtet werden:

- Methodische Expertise.
- Data-Governance und Datenqualität.
- Rollen in Data-Science-Teams.

Data-Science-Projekte müssen sich mit der Tatsache auseinandersetzen, dass jede Organisation ihre eigene Dateninfrastruktur aufweist. Ähnliches gilt für die methodische Expertise, Data-Governance und Datenqualität sowie die vorhandenen Rollen in Data-Science-Teams oder der Organisation. Damit Lücken zwischen Möglichkeiten und Anforderungen an Data-Science geschlossen werden können, sind die Schritte zur Wertschöpfung aus Daten sorgfältig unter Berücksichtigung dieser Rahmenbedingungen festzulegen.

Methodische Expertise: Abbildung 2.9 zeigt eine Übersicht methodischer Kernbegriffe, die in der Datenwertschöpfungskette von Bedeutung sind, sowie ihre groben Zusammenhänge.

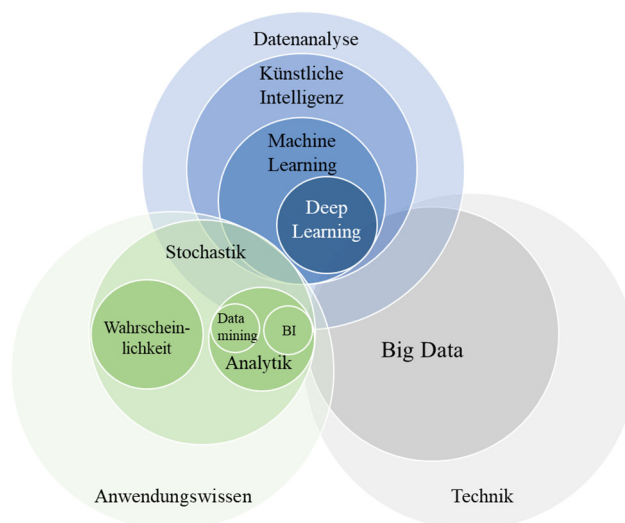


Abb. 2.9: Übersicht über Kernbegriffe und ihre Zusammenhänge (vgl. Heinrichs 2019; Kordon 2020, S. 16)

Um die Daten für Anwendende greifbar und verständlich aufzubereiten, ist eine Datenanalyse erforderlich. Im Ergebnis entstehen Datenprodukte, die für eine Organisation einen Mehrwert aus Daten schaffen (vgl. Stockinger et al. 2016). Für diese Arbeit besteht ein Datenprodukt aus mindestens einer klaren und für die Organisation relevanten Fragestellung, die es mithilfe von Datenanalysen zu beantworten gilt. Hierzu muss die Interpretation des Datenprodukts nachvollziehbar festgelegt sein (Entscheidungsgrenzen). Dessen ungeachtet sind die Datenquelle und die Verarbeitung des Datenprodukts möglichst klar zu definieren. Daneben benötigt Data-Science verschiedene Techniken, Prozesse, Prinzipien und beteiligte Rollen.

In Bezug auf maschinelles Lernen finden sich überwachte (supervised) und unüberwachte (unsupervised) Methoden (vgl. Brühl 2019, S. 5; Kordon 2020, S. 8). Beim überwachten Lernen werden zunächst relevante Daten durch Anwendende ausgewählt. Durch diese Informationen wird der Algorithmus trainiert, um Schlussfolgerungen und Vorhersagen zu generieren (vgl. Brühl 2019, S. 6). Beim unüberwachten Lernen entdeckt der Algorithmus Ähnlichkeiten und ordnet die Daten selbst gewählten oder vorbereiteten Kategorien zu (vgl. Brühl 2019, S. 6).

Reinforcement-Learning ist eine weitere Form des maschinellen Lernens; dabei wird das Modell durch Fehler und Belohnungen konditioniert, um in seiner Einsatzumgebung bestmögliche Ergebnisse bei der Erledigung der definierten Aufgaben zu erzielen (vgl. Brühl 2019, S. 5 f.; Kampakis 2020, S. 80).

Datengestützte Entscheidungsprozesse überbrücken die Kluft zwischen Datenanalyse und Anwendenden. Datengestützte Entscheidungsverfahren hängen nicht nur von Fachleuten, ihren Fähigkeiten sowie ihrem Wissen ab, sondern gleichsam von der Datenqualität, der Analysemethodik und den Ergebnissen.

2.5 Data-Governance und Datenqualität

Daten sind eine wertvolle Geschäftsressource, um gute Entscheidungen zu treffen (vgl. Seiner 2014, S. 65). Je nach organisationseigenen Strategien zur Wertschöpfung aus Daten lassen sich aus der Datenwertschöpfungskette verschiedene Handlungsempfehlungen ableiten. Die Teile der Datenwertschöpfungskette sind voneinander abhängig, sodass Daten, die zwar gesammelt, aber nicht gut verwaltet werden, keinen Nutzen aufweisen. Neben einem gemeinsamen Verständnis von Ontologien und Datenmanagement ist Data-Governance entscheidend für die Definition von Rollen und Prozessen für den Umgang mit Daten in Organisationen. Zur Data-Governance gehört es, Richtlinien, Standards, Metriken und Rollen für die Datenverwaltung festzulegen und dafür zu sorgen, dass sie eingehalten werden (vgl. Mahanti 2021, S. 1). Dabei ist es wesentlich, dass diese Rollen, ihre Aufgaben und Verantwortlichkeiten eine Brücke zwischen IT und Business schlagen (vgl. Seiner 2014, S. 107). Dafür sollen Daten und Data-Governance in der Verantwortung jedes*jeder Einzelnen

liegen. Um dies zu erreichen, muss die Kultur vom Management aus geändert werden. Das Management legt klare Ziele, Regeln und Verhaltensanweisungen fest, die anhand von Datenqualitätsdimensionen bewertet werden können (vgl. Seiner 2014, S. 65). Nur so kann die Wertschöpfung einer Organisation verbessert werden (siehe Abb. 2.10).

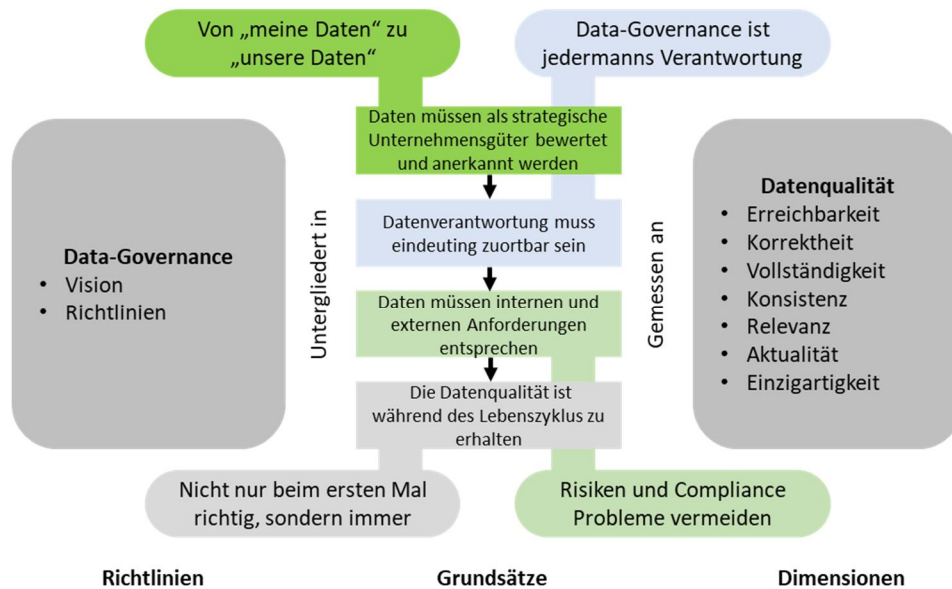


Abb. 2.10: Richtlinien, Grundsätze und Dimensionen noninvasiver Data-Governance (vgl. Seiner 2014, S. 65)

Der erfolgreichen Einführung von Data-Governance stehen indes Herausforderungen entgegen. Neben der Managementunterstützung und der Organisationskultur muss eine gemeinsame Sprache (Semantik) gefunden werden (vgl. Mahanti 2021, S. 11). Eine Literaturrecherche zu Data-Governance identifizierte technische, rechtliche und organisatorische Herausforderungen (vgl. Al-Ruithe et al. 2019, S. 847). Die meisten Herausforderungen finden sich in der organisatorischen Implementierung von Data-Governance. Neben den Rollen und Verantwortlichkeiten müssen ebenfalls Prinzipien, Richtlinien und Prozesse festgelegt werden. Training und Ausbildung sollen sicherstellen, dass Mitarbeitende verstehen, wie Data-Governance in Organisationen gelebt werden soll. Um den organisatorischen Herausforderungen zu begegnen, können Konzepte wie *noninvasives Data-Governance* genutzt werden (vgl. Seiner 2014, S. 103). Dieses Konzept beschreibt, wie bestehende Entscheidungsstrukturen dazu dienen können, Data-Governance innerhalb einer Organisation zu etablieren, ohne dabei parallel gravierende Veränderungsprozesse anstoßen zu müssen (vgl. Seiner 2014, S. 34). Das Betriebsmodell der noninvasiven Data-Governance lässt sich, wie in Abb. 2.11 gezeigt, auch für die Betriebsführung und Instandhaltung von Onshore- sowie Offshore-Windparks heranziehen.

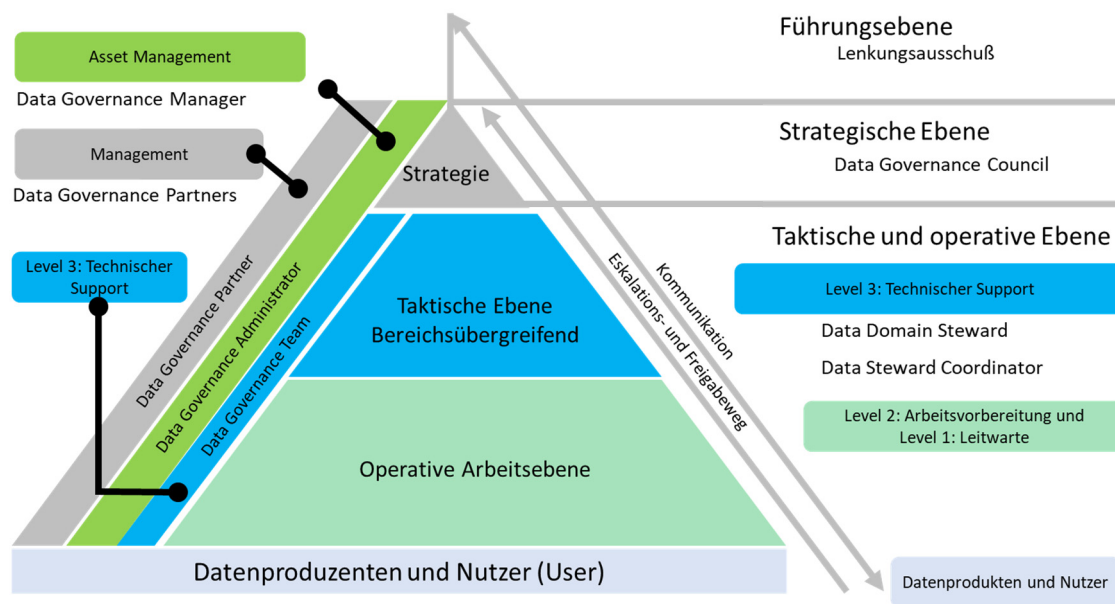


Abb. 2.11: Noninvasives Data-Governance im Betrieb von Onshore- und Offshore-Windparks
(vgl. Seiner 2014, S. 103)

Innerhalb des Betriebsmodells werden den bestehenden strategischen, taktischen und operativen Ebenen unterstützende Funktionen zugeordnet. Das Data-Governance-Team sorgt dafür, dass die festgelegten Richtlinien, Verantwortlichkeiten und Prozesse eingehalten werden. Die Data-Governance-Administrator*innen geben diese vor. Data-Governance-Partner*innen wie das Management steuern Prinzipien bei oder unterstützen bei rechtlichen Fragen. Praktische Werkzeuge wie die *Common Data Matrix* können genutzt werden, um festzulegen, wer welche Daten managt, pflegt, in welcher Software die Daten verwaltet werden und wer sie nutzt (vgl. Seiner 2014, S. 168). Dieses Tool kann als ein stark vereinfachter Datenkatalog verstanden werden. Ein weiteres Tool ist die *Governance Activity Matrix* (vgl. Seiner 2014, S. 178 f.). Sie definiert, welche Aktivitäten die verschiedenen Level durchführen:

- Die Data-Governance-Partner*innen unterstützen das Data-Governance-Team bei der Abstimmung hinsichtlich der taktischen und operativen Funktionen (vgl. Seiner 2014, S. 156).
- Das Data-Governance-Team hilft bei der Umsetzung von Data-Governance-Vorgaben, erstellt Best Practices und schult Mitarbeitende (vgl. Seiner 2014, S. 158).
- Data-Governance-Manager*innen beaufsichtigen das Data-Governance-Team und fördern die Data-Governance innerhalb der gesamten Organisation.
- Das Data-Governance-Council als Spitze der Pyramide definiert die Data-Governance-Strategie und legt Kernrollen wie die Stewards und Prozesse fest (vgl. Seiner 2014, S. 144).
- Data-Domain-Stewards benennen Data-Steward-Koordinator*innen (vgl. Seiner 2014, S. 138).

- Data-Steward-Koordinator*innen zeichnen für die Einhaltung der Datenpolitik verantwortlich (vgl. Seiner 2014, S. 138).

Für die Einführung der noninvasiven Data-Governance kann eine *Kommunikationsplan-Matrix* genutzt werden; sie verbindet die Verantwortlichkeiten mit den vorab definierten Rollen (vgl. Seiner 2014, S. 191 ff.).

2.6 Data-Science-Teams

Das Verständnis von Data-Science-Problemen setzt ein bestimmtes Kompetenzprofil für Data-Scientist*innen voraus. Dazu gehören Methodenkompetenz, Domainwissen und die Fähigkeit, zwischen beiden eine Brücke schlagen zu können, etwa durch Data-Storytelling. Hinsichtlich der Methoden werden neben Programmierkenntnissen auch mathematische sowie statistische Kompetenzen benötigt (vgl. Kampakis 2020, S. 107). Das Domainwissen umfasst Wissen über das Einsatzfeld der Datenprodukte. Data-Science bildet mithin Überschneidungspunkte zwischen dem Domainwissen und den mathematischen und statistischen Kompetenzen, um diese Methoden und Verfahren zum Erkenntnisgewinn zu nutzen (vgl. Ozdemir und Kakade 2018, S. 7).

Data-Science ist ein *Teamsport* (vgl. Howells 2020): Neben den Data-Scientist*innen werden auch Data-Engineers benötigt (vgl. altexsoft 2017), die eine funktionierende Infrastruktur zur Verarbeitung von Big Data schaffen. Bereits diese beiden Rollen lassen sich abgrenzen. Data-Scientist*innen unterstützen auch in klassischen Software-Entwicklungsteams und nehmen dabei verschiedene Rollen an; ab einer gewissen Komplexität werden Data-Science-Projektteams notwendig (vgl. Kim et al. 2016, S. 101 ff.). Die ideale Struktur und Größe eines Data-Science-Teams hängen indes stark vom Projektumfeld und von der Zielsetzung einer Organisation oder des Projekts ab. Eine erste Erweiterung wird durch einen Anwendenden (Subject Matter Expert) erreicht, um sicherzustellen, dass die mit der Analyse zu beantwortende Fragestellung Relevanz für die Anwendungsdomäne besitzt (vgl. Dhungana 2019).

Data-Scientist*innen lösen geschäftsrelevante Fragestellungen einer Organisation mithilfe von Methoden der Data-Science. Um die besten Ergebnisse zu erzielen, müssen sie sich mit einer Vielzahl von Themen und Methoden auseinandersetzen. Dabei ist es wesentlich, auch die Grenzen des eigenen Wissens zu kennen, um sich bei Bedarf Rat von anderen Anwendenden zu holen (vgl. Dhungana 2019). Im Kern geht es bei den Aufgaben von Data-Scientist*innen um die Datenvorbereitung und -bereinigung, das Training der Modelle sowie die zielgruppengerechte Auswertung und Darstellung von Ergebnissen.

Data-Engineers setzen die Vorgaben der Data-Scientist*innen (oder der Datenarchitekt*innen) für die Infrastruktur zur Datensammlung und -analyse um. Eine weitere Aufgabe bezieht sich auf den

Betrieb und die Instandhaltung der Infrastruktur. Je nach Komplexität des Projekts können Data-Engineers Aufgaben oder Funktionen des*der Datenarchitekt*in übernehmen.

Anwendende oder Fachanalyst*innen (Subject Matter Experts) aus der Anwendungsdomäne, in der die Fragestellung durch Data-Science gelöst werden soll, helfen, die Praxisrelevanz sicherzustellen.

Größere Firmen benötigen eine komplexere Struktur. So kann ein Chief Analytics Officer oder ein Chief Data Officer nötig sein; daneben gibt es weitere Rollen (vgl. altexsoft 2017).

Die Rolle des*der Data-Analyst*in stellt sicher, dass die gesammelten Daten relevant und vollständig sind, während er*sie gleichzeitig die Analyseergebnisse interpretiert. Hierfür sind Visualisierungsfähigkeiten erforderlich, um Informationen grafisch aufzuarbeiten.

Ingenieur*innen für maschinelles Lernen bestimmen, welche Daten mit welcher Methode ausgewertet werden. Dabei nutzen sie ihr Wissen in den Bereichen Wahrscheinlichkeitsrechnung und Statistik. Sie bereiten Daten vor und erstellen, trainieren, überwachen und warten Analysemodelle.

Datenjournalist*innen (Data Journalists) helfen dabei, Geschäftsprobleme und Analyseergebnisse durch Data-Storytelling in einen Kontext zu setzen. Programmier- und Statistikkenntnisse sind vonnöten, um die Ideen und Ergebnisse des Data-Science-Teams verschiedenen Stakeholdern oder Anwendenden ohne Statistikkenntnisse präsentieren zu können.

Die Rolle des*der Datenarchitekt*in (Data Architect) ist entscheidend für die Arbeit mit Big Data. Speziell bei großen verteilten Informationen ist die Datenbankarchitektur zur Sicherstellung der Integrität und Leistung des Systems zentral.

Visualisierungsfachleute (Application/Data Visualization Engineer) können in komplexeren Data-Science-Projekten die Visualisierung der Ergebnisse als Frontend zu den Anwendenden betreuen. Grundsätzlich können diese Aufgaben aber auch nach Vorgaben des*der Data-Scientist*in von Software- oder Applikationsingenieur*innen durchgeführt werden. Andere Quellen sprechen hierbei von *Informationsdesignern*, die sich wie Inneneinrichtende um die Nutzbarkeit und eine positive Erfahrung der Anwendenden kümmern (vgl. Kesari 2020).

Gegebenenfalls müssen auch klassische Fragestellungen der BI ergänzt oder integriert werden. Für eine optimale Wertschöpfung sollten Rollen bestmöglich in Geschäftsprozesse, Berichte und Dashboards eingebunden sein (vgl. Mohanna und Shaw 2019), z. B. folgendermaßen:

BI-Analyst*innen bilden die Schnittstelle zwischen Data-Scientist*innen und Business-Analyst*innen.

Die Rolle des*der Business-Analyst*in betreut die Prozessoptimierung innerhalb von Organisationen. Data-Storytelling verbindet Geschäftsbereiche und Data-Analyst*innen. Zu den Kompetenzen dieser Rolle gehören BI-Kenntnisse und ein Verständnis verschiedener Anwendungsdomänen. Die Aufgaben können Berichterstattung und Entwicklung neuer Datenanalysen umfassen.

Die Rolle des*der Analytics-Architekt*in wird in größeren Data-Science-Projekten oder in komplexeren Organisationen benötigt, um die Architektur der Analysen zu erstellen. Hierbei geht es darum, das Data-Science-Team zu leiten, diesem die Anforderungen an die Analysen in Form von Anforderungsprofilen zu vermitteln und Analytics-Services zu etablieren.

Data-Stewards gewährleisten die Datenqualität und kümmern sich darum, dass Organisationsprozesse z. B. zur Datensicherheit oder Datenethik befolgt werden (vgl. Wyss 2019).

Es existieren verschiedene Möglichkeiten zur Integration der Data-Science-Teams innerhalb von Organisationen (vgl. Mohanna und Shaw 2019). Dabei kann etwa eine zentralisierte, eine dezentralisierte oder eine beratende (Consulting-)Einbindung angestrebt werden (vgl. Mohanna und Shaw 2019). Ergänzend kann noch die Möglichkeit einer funktionalen Ausrichtung des Teams erwähnt werden (vgl. altexsoft 2017).

Bei zentralisierten Teams sind Data-Scientist*innen als Gruppe oder Team organisiert und arbeiten gemeinsam als Abteilung, um die Fragestellungen anderer Abteilungen auf Basis von Analytik zu beantworten. Das Team wird zentral finanziert, damit auch strategische, für die Organisationen langfristig relevante Entwicklungen durchgeführt werden können.

Dezentralisiert sind Teams dann, wenn die Data-Scientist*innen in einer Organisation verteilt sind und funktionale Fragestellungen aus der Abteilung übernehmen, in der sie aufgrund der vorkommenden Datenprodukte eingestellt wurden. Es kann sich dabei auch um Einzelpersonen handeln, die nicht in einer übergeordnet koordinierten Struktur für Data-Scientist*innen organisiert sind. Die Dezentralisierung kann durch die hohe Autonomie der Data-Scientist*innen eine Standardisierung in diesem Bereich erschweren und zu dezentralem Reporting führen.

Funktionale Data-Scientist*innen werden dort eingesetzt, wo der Bedarf am größten ist. Speziell wenn Analytik in einer Organisation noch nicht weitverbreitet ist, kann diese Struktur ideal sein.

Im Fall des beratenden Einsatzes (Consulting) betreuen Data-Scientist*innen einzelne oder mehrere Abteilungen, um Datenprodukte zu bearbeiten. Dabei wird ihr Einsatz von den verschiedenen Abteilungen projektbezogen finanziert, dadurch entstehen abteilungsspezifische Lösungen.

Neben diesen Teamarten existieren auch andere Ansätze, die sich mit der Einbettung der Teams in eine Organisationsstruktur beschäftigen. Data-Science-Teams, die in getrennten Silos (sogenannten *thematischen Blasen*) arbeiten, fällt es schwer, Lösungen einzubetten oder zu integrieren (vgl. Zaharia 2020). Unterschieden werden kann in den *Hub-* und den *Spoke-*Ansatz (vgl. Howells 2020). Ein *Hub*, *Lab* oder *Center of Excellence* ist eine Unterform des zentralisierten Data-Science-Teams. Die *Spokes* sind als *Sprechende* dezentral in den betreffenden Abteilungen beschäftigt; sie können auch als *Squads*, *Pods* oder *Business Engagement Teams* bezeichnet werden (vgl. Howells 2020). Der Hub legt dabei die Strategie fest und sorgt für Standardisierung sowie für langfristige Entwicklungen. Aufgrund der langfristigen Entwicklungen ist dieses Team ähnlich wie ein Software-

Entwicklungsteam mit Scrum Master und Softwareentwickler*innen, Product Owners, Business-Analysts sowie Testenden ausgestattet (vgl. Howells 2020). Die Spokes, bestehend aus Data-Scientist*innen sowie Visualisierungsfachleuten, erarbeiten relevante Lösungen für die betreffenden Geschäftseinheiten. In Kombination bilden das Hub- und das Spoke-Team damit Mischformen, die die Vorteile der zentralisierten und dezentralisierten Teams vereinen (vgl. Howells 2020).

Data-Science unterliegt einer stetigen Weiterentwicklung als Fachrichtung sowohl innerhalb der Team-Struktur als auch im Bereich der verwendeten Methoden (z. B. Cloud-Datenspeicherung) oder Werkzeuge (vgl. Mohanna und Shaw 2019). Dieses kontinuierliche Anpassen an verschiedene Infrastrukturen sowie an neue Methoden und Werkzeuge bildet neben der adressatengerechten Darstellung der Ergebnisse eine der Kernherausforderungen (vgl. Mohanna und Shaw 2019).

3 Evaluationsmodell und Visualisierung der Datenwertschöpfungskette

In diesem Kapitel wird die Ontologie der Datenwertschöpfungskette durch qualitative Inhaltsanalysen anhand einer Literaturrecherche entwickelt. Die Datenwertschöpfungsketten-Ontologie besteht aus fünf Bestandteilen: Ein Kategorisierungssystem kategorisiert Datenprodukte, das Datenwertschöpfungsketten-Canvas beschreibt Datenprodukte detaillierter, das Bewertungsmodell ermöglicht die Bewertung der Datenwertschöpfungskette durch Evaluationsteilnehmende, und das Kennzahlensystem definiert objektive Bewertungskriterien, die schließlich eine Visualisierung der Evaluationsergebnisse ermöglichen. Innerhalb der Datenwertschöpfungsketten-Ontologie werden die Begrifflichkeiten und Zusammenhänge des Evaluationsmodells veranschaulicht. Sunburst- und Sankey-Diagramme werden verwendet, um die Datenwertschöpfungskette darzustellen. Die Funktion wurde in einem Software-Prototyp für einen Proof of Concept integriert, um das Bewertungsmodell mit Industriepartnern durchzusprechen und zu prüfen. Der Datenfluss muss dafür ganzheitlich betrachtet werden und reicht von der Betrachtung der Datenquelle über das Datenmanagement, verschiedene Datenanalysen, etwa durch externe Software oder Eigenentwicklungen, bis hin zu den Entscheidungen, die dadurch unterstützt werden. Damit eine effiziente Entscheidung getroffen werden kann, müssen alle relevanten Informationen zum adäquaten Zeitpunkt bei den entscheidungsverantwortlichen Anwendenden vorliegen. Um sich dieser Herausforderung zu stellen, müssen die Methoden der Evaluation von verschiedenen Interessenvertretenden mit unterschiedlichem fachlichen Hintergrund verstanden werden können. Das Ziel der gewählten Evaluationsmethode besteht darin, die Datenwertschöpfungskette transparent zu visualisieren, um Optimierungspotenziale zu identifizieren und zu analysieren.

Eine Datenwertschöpfungsketten-Ontologie ermöglicht die Analyse, Darstellung und Verbesserung der Wertschöpfung aus Daten. Aufgrund der Einzigartigkeit von Datenwertschöpfungsketten muss das Modell formbar und erweiterbar sein, um zeitlose Gültigkeit und Übertragbarkeit zu erreichen.

Teile dieses Abschnitts wurden für die *1st International Conference on Technological Advancement in Embedded and Mobile Systems (ICTA-EMoS)*-Konferenz (vgl. Bendlin et al. 2023) für die Veröffentlichung akzeptiert und 34 in dem Springer-Buch *Development Methodologies for Big Data Analytics Systems – plan-driven, agile, hybrid, lightweight approaches* (vgl. Bendlin et al. 2024) veröffentlicht worden.

3.1 Qualitative Inhaltsanalyse der Literaturrecherche

Bei der Literaturrecherche wurde eine deduktiv-induktive Vorgehensweise gewählt; Eine Übersicht der verschiedenen Methoden bietet Abb. 3.1. Anhand von Vorarbeiten (vgl. Haneke 2019; Hötzl

2022; Kruse et al. 2018)²⁴ wurden mögliche Literaturquellen identifiziert und eine Vorkategorisierung durchgeführt. Aus diesem deduktiven Vorgehen wurden eine initiale Kategorisierung, erste Kernquellen sowie Schlüsselwörter ermittelt. Im Anschluss wurden diese Kategorien über eine induktive Literaturrecherche und Inhaltsanalyse nach Mayring verfeinert und ergänzt (vgl. Mayring 2015, S. 17). Die induktive Analyse wurde ebenfalls zur Auswertung und Analyse der Protokolle der Interviews mit Expert*innen verwendet.

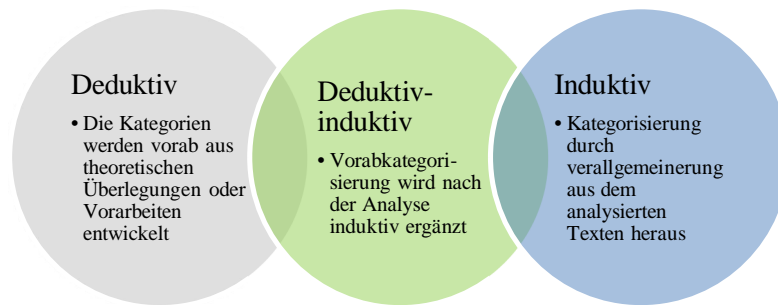


Abb. 3.1: Formen der Inhaltsanalyse (vgl. Mayring 2015, S. 85)

Die Inhaltsanalyse nach Mayring beschreibt eine theoriegeleitete, systematische Methode, um Inhalte in Bezug auf „bestimmte Aspekte der Kommunikation“ zu untersuchen (Mayring 2015, S. 13).²⁵ Innerhalb der Methodendiskussion schlägt Mayring vor, die qualitative Inhaltsanalyse als qualitativ-orientierte Inhaltsanalyse zu bezeichnen, da dieser Ausdruck die verwendete Mischung aus qualitativen und quantitativen Ablaufschritten besser beschreibt (vgl. Mayring 2015, S. 17).

Die Grundanforderungen, um eine qualitative Inhaltsanalyse durchzuführen, können wie folgt definiert werden (vgl. Mayring 2015, S. 29):

Die qualitative Inhaltsanalyse...

- ... wird durch quantitative Techniken glaubwürdiger.
- ... betrachtet das Material als Teil eines Kommunikationsmodells/ einer -kette.
- ... setzt dieselben Grundbegriffe voraus.
- ... muss sich anhand wissenschaftlicher Qualitätsmerkmale bewerten lassen.

²⁴ Das BMC ist ein geeignetes Werkzeug, um die Wertschöpfung von Datenprodukten im Organisationskontext zu beschreiben (vgl. Haneke 2019, S. 46 f., 52 ff., 58). Kruse et al. entwickelten ein *Data Product Profile*, das verschiedene Variablen umfasst, um Datenprodukte zu definieren und die Kommunikation zwischen Anwendenden und Data-Scientist*innen zu verbessern (vgl. Kruse et al. 2018, S. 3). In seiner Masterarbeit erstellt Hötzl aus einer Literaturrecherche einen Datenprodukt-Steckbrief und evaluiert diesen mithilfe von Expert*innen (vgl. Hötzl 2022, S. 3 f.).

²⁵ Als Grundtechniken definiert er die Häufigkeits- oder Frequenzanalyse, die Valenz- und Intensitätsanalyse sowie die Kontingenzanalyse, (vgl. Mayring 2015, S. 13 ff.). Bei der Häufigkeits- oder Frequenzanalyse wird die Häufigkeit oder Frequenz von Textelementen analysiert (vgl. Mayring 2015, S. 13 ff.). Die Valenz- und Intensitätsanalyse skaliert und vergleicht Textelemente (vgl. Mayring 2015, S. 15). Die Kontingenzanalyse befasst sich mit der Analyse der Beziehung von Textelementen, etwa unter der Fragestellung, wie „häufig sie im gleichen Zusammenhang auftauchen“ (vgl. Mayring 2015, S. 16).

Ziel einer qualitativen Inhaltsanalyse ist es, ein natürliches Verständnis des Textmaterials ohne eigene Einschätzungen zu erarbeiten, um eine Grundlage für Um- oder Weiterinterpretation durch andere zu bilden (vgl. Mayring 2015, S. 38). Der Prozess zur qualitativen Inhaltsanalyse orientiert sich am menschlichen Prozess der Textverarbeitung. Im Kern stehen dabei die Kategoriendefinition und die Kategorisierung der Quellen (vgl. Mayring und Fenzl 2019, S. 641). Als Alternative zu einer qualitativen Inhaltsanalyse können auch andere qualitative Methoden wie die *Grounded Theory* herangezogen werden (vgl. Kuckartz 2014, S. 113). Die *Grounded Theory* wurde unter diesem Namen erstmals 1967 von Glaser und Strauss in ihrem Werk *The discovery of Grounded Theory* veröffentlicht (vgl. Glaser und Strauss 2017, S. IX). Nach Ansicht der Autoren ist die *Grounded Theory* – im Gegensatz zur logisch-deduktiven, auf Annahmen basierenden Theorieentwicklung – für die Entwicklung zweckgerichteter Theorien besser geeignet (vgl. Glaser und Strauss 2017, S. 3). Die Theorie gibt ein genaues „Vorgehen für die Kodierung und Auswertung“ vor und setzt auf „induktive Gewinnung neuer Theorien durch intensive Beobachtung des Untersuchungsgegenstandes im Feld“ (Balzert et al. 2017, S. 285). Ein Kritikpunkt ist der „offene, explorative“ Charakter der *Grounded Theory*, während die qualitative Inhaltsanalyse fragebezogen arbeitet (Mayring 2019, S. 3). Aufgrund dieses Vorteils erweist sich die qualitative Inhaltsanalyse zur Beantwortung der Forschungsfragen der vorliegenden Arbeit als geeigneter.

3.2 Evaluationsmodell

Der Datenfluss und seine Wertschöpfung müssen in Organisationen aufgrund der organisatorischen Strukturen und Abläufe individuell verstanden und untersucht werden. Dafür ist ein mehrstufiger, iterativer Prozess vonnöten. Das Evaluationsmodell der Datenwertschöpfungskette folgt diesem Ablauf und wird im Weiteren anhand von Abb. 3.2 grob umschrieben. Eine detailliertere Beschreibung folgt in den weiteren Unterkapiteln dieses Kapitels.

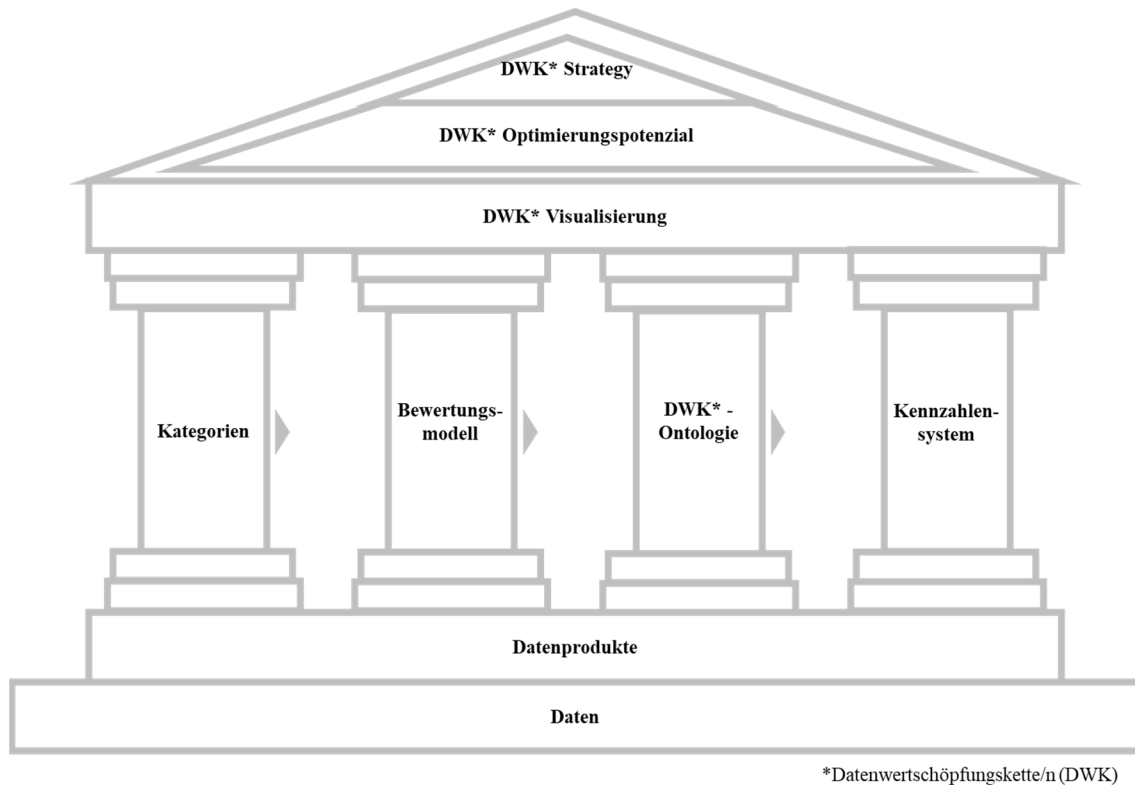


Abb. 3.2: Schematische Übersicht über die Bestandteile der entwickelten Datenwertschöpfungskette

Grundlage der Datenwertschöpfungskette sind Daten in ausreichender Qualität; daraus lassen sich relevante Fragestellungen in Form von Datenprodukten ableiten. Eine Kategorisierung durch Anwendende beruht auf Ähnlichkeiten oder theoretischem Vorwissen. Dadurch können Befragungen und Auswertungen strukturiert werden. Um die Datenprodukte zu detaillieren und im Organisationskontext zu verorten, wird ein Datenwertschöpfungsketten-Canvas verwendet. Ein Bewertungsmodell definiert die Skalierung, anhand derer die Bestandteile der Datenwertschöpfungskette beurteilt werden können. Das Kennzahlensystem bietet objektive Bewertungskriterien als Basis für die Analyse und Visualisierung der Datenwertschöpfungskette.

Daten: Daten werden als das *neue Öl* für die nächste industrielle Revolution bezeichnet (vgl. Humby 2006). Diese Bezeichnung wurde von verschiedenen Autor*innen übernommen (vgl. Kordon 2020, S. 40 f.; Stockinger et al. 2016, S. 60); die Formulierung erklärt die abstrakte Verbindung zwischen Daten und Wertschöpfung. Daten werden dabei mit Rohöl und dem komplizierten Raffinationsprozess verglichen.

Datenprodukte: Datenprodukte als relevante Fragestellungen, die durch Datenanalyse beantwortet werden können, dienen als Grundlage für die Datenwertschöpfungskette. Durch das Datenwertschöpfungsketten-Canvas können die Datenprodukte weiter detailliert werden.

Kategorisierung: Im ersten Schritt werden Datenprodukte kategorisiert. Durch Ambitionslevel lassen sich diese Kategorien priorisieren. Sie werden in einem Sunburst-Diagramm dargestellt, um die Anforderungen verschiedener Stakeholder oder Organisationseinheiten in die Bewertung einzubeziehen. Im nächsten Schritt können zusätzliche Datenprodukte anhand der Kategorien identifiziert werden. Die Kategorien fungieren zusätzlich als Filter für die finale Visualisierung.

Bewertungsmodell: Nachdem die Datenprodukte der einzelnen Kategorien festgelegt sind, erfolgen eine Priorisierung und eine Bewertung der Datenprodukte. Eine initiale Priorisierung wird durch die Bewertung der Wertschöpfung und des Implementierungsaufwands für die Datenanalysemethode erreicht. Mittels dieser Priorisierung können weitere Aspekte der Datenwertschöpfungskette bewertet werden. Zusätzlich lassen sich weitere Bestandteile der Datenwertschöpfungskette über eine festgelegte Skalierung einstufen.

Datenwertschöpfungsketten-Ontologie: Die Ontologie der Datenwertschöpfungskette legt fest, welche *Elemente* zu jedem Datenprodukt definiert werden sollten und wie diese zusammenhängen. Diese Variablen helfen dabei, das Datenprodukt im Wertschöpfungskontext der Organisation zu verorten und Begrifflichkeiten einheitlich zu beschreiben.

Kennzahlensystem: Das Kennzahlensystem bildet einen eingängigen Prozess ab, bei dem die Bewertungsschritte logisch aufeinander aufbauen. Um diese Anforderungen zu erfüllen, werden relevante Kennzahlen definiert und passend zu den Forschungsfragen kombiniert.

Visualisierung: Um eine einfache Durchführung von Workshops und Ergebnispräsentation zu ermöglichen, sollten eine Visualisierung und Auswertung von Teilergebnissen möglich sein. Damit soll der Analyseprozess transparenter werden, um *Blackbox*-Modelle zu vermeiden; durch die Visualisierung von Zwischenschritten können Rückmeldungen von Anwendenden genutzt werden, um den weiteren Prozess während der Modellierung anzupassen (vgl. Bitkom 2014, S. 85). Dasselbe gilt für die Datenwertschöpfungskette: Durch verschiedene Zwischenstufen der Visualisierung wird ein transparenter Evaluationsprozess ermöglicht.

3.3 Datenprodukte und Kategorisierungssystem

Als Ergebnis der Datenanalysen entstehen Datenprodukte. Dabei können drei Arten von Datenprodukten unterschieden werden (vgl. Tempich und Rieger 2007). Bei *Data as a Service* handelt es sich um Datenprodukte, die als Geschäftsmodell aus Daten ein vermarktbare Produkt erstellen. Eine weitere Art sind die *Data-enhanced Products*: Hier werden vorhandene Produkte durch Daten angereichert; als Beispiel kann das Empfehlungssystem eines Onlineshops genannt werden (vgl. Tempich und Rieger 2007). Die letzte Art sind *Data as Insights*: Hierbei geht es um den Wissensgewinn durch interne oder externe Datenquellen zur Entscheidungsunterstützung (vgl. Haneke 2019,

S. 47). In dieser Arbeit liegt der Fokus auf Data as Insights. Dabei gilt die für diese Arbeit gewählte Definition: *Ein Datenprodukt ist eine relevante Frage, die mithilfe von Daten (Analyse) beantwortet werden kann.*

Im Bereich Windenergie ergeben sich als Datenprodukte beispielsweise Wetterprognosen aus historischen Wettermessdaten oder aus Wettermodellldaten (vgl. Optis et al. 2021, S. 5; Wolken-Möhlmann et al. 2016, S. 518). Klassische Datenprodukte umfassen einfache Fragestellungen der BI. Data-Science-Analysen zeichnen sich durch die Verbindung historischer und Live-Messdaten zur Beantwortung komplexer Fragestellungen wie etwa der Vorhersage zukünftiger Ereignisse aus (vgl. Gross et al. 2016, S. 1; Loukides 2011). Durch Data-Storytelling als anwendungsorientierte Visualisierungstechnik können auch solche komplexeren Daten von Anwendenden schnell erfasst werden. Mithin können Daten und Datenprodukte als Ergebnisse von Datenanalysen als kritische Ressourcen für Entscheidungsprozesse in Organisationen betrachtet werden. *Key Performance Indicators*.²⁶ (KPIs) als definierte Kennzahl zur Leistungsbewertung relevanter Messgrößen²⁷ können fest mit Datenprodukten verbunden sein. Dabei ist zu beachten, dass verschiedene Interessenvertretende unterschiedliche KPIs nutzen und auch unterschiedliche Anforderungen an KPIs haben. So brauchen Techniker*innen vor Ort andere Informationen als die Geschäftsleitung oder Ingenieur*innen, die eine Ursachenanalyse zu einem Fehler durchführen. Einige Fragestellungen für die Datenwertschöpfungskette oder Datenprodukte können durch abgeleitete KPIs definiert oder strukturiert werden, um so eine Bewertung zu ermöglichen.

Für die Kategorisierung von KPIs finden sich verschiedene Ansätze in der Literatur. Im AWESOME-Forschungsprojekt²⁸ wurden unterschiedliche Anforderungen der Interessenvertretenden definiert. Diesen Interessengruppen wurden dann KPIs für Leistung, Zuverlässigkeit, Wartung, Finanzen und Sicherheit zugewiesen (vgl. Gonzalez et al. 2017, S. 561 ff.). Neben den vorgestellten Gruppierungen bieten sich je nach Zielrichtung der Befragung oder je nach Interessenvertretenden

²⁶ Grundsätzlich können KPIs danach bewertet werden, ob ihr Ergebnis zu einer Entscheidung führt oder für eine Bewertung genutzt wird. Weiterhin kann dahingehend differenziert werden, ob die Kennzahl vergangene Ereignisse und Daten bewertet (*Lagging*) oder sich auf zukünftige Ereignisse bezieht (*Leading*) (vgl. QlikTech International AB 2019, S. 5f.). Lagging-KPIs analysieren die Zielerfüllung nach Abschluss einer Aktivität oder eines Arbeitsprozesses. Leading-KPIs ermöglichen Auskünfte über Trends und erlauben damit Rückschlüsse in Bezug auf den Verlauf oder das Ergebnis von Prozessen. Abweichungen zu einem Referenzwert dienen als Indikator für eine Aktion oder eine genauere Untersuchung (vgl. Pfaffel et al. 2020, S. 2). Betriebliche Effizienz und Transparenz sind ohne die Messung von KPIs nicht möglich (vgl. Oswald et al. 2011, S. 5).

²⁷ Beispielsweise kann der Status (in Produktion oder in Störung) einer Windenergieanlage in Form einer KPI definiert sein.

²⁸ Das europäische *Advanced Wind Energy System Operation and Maintenance Expertise* (AWESOME)-Projekt forschte zur Verbesserung der Betriebs- und Wartungsplanung von Windparks unter anderem durch Definition von KPIs (vgl. Gonzalez-Rodriguez 2017, S. 560).

auch andere Indikatoren an, z. B. Gesundheit, Sicherheit, Umwelt und Qualität (vgl. Antão et al. 2016, S. 273), oder eine Einteilung in Fehlerklassen (vgl. Alewine und Chen 2010, S. 5).

In ihrer ursprünglichen Fassung wird in der EN-Norm *Maintenance – Maintenance Key Performance Indicators* (vgl. CEN 2007, S. 7) vorgeschlagen, zwischen externen und internen Faktoren zu unterscheiden. Die Kennzahlen werden weiter in ökonomische (economic), technische (technical) und organisatorische (organizational) Indikatoren aufgeteilt (vgl. CEN 2007, S. 7). Im Jahr 2019 wurde die Norm revidiert und eine neue Klassifizierung eingeführt (vgl. CEN 2019). Dabei wurden acht Haupt- mit je vier Unterbereichen definiert (siehe Tab. 3.1).

Maintenance Function main areas	SUB AREAS			
Physical Asset-Management	Sustainability	Capacity, Effectiveness, Integrity	Service Level	Economics
Sub-function 1 Health - Safety Environment	Laws- Rules conformity	Statistical Records	Safe Practice	Prevention and Improvements
Sub-function 2 Maintenance Management	Strategy	Function	Technical Assessment	Continuous Improvement
Sub-function 3 People Competence	Maintenance Manager	Maintenance Supervisor/ Maintenance Engineer	Maintenance Technician Specialist	Education
Sub-function 4 Maintenance Engineering	Capability Criticality	Durability	Preventive Maintenance	Engineering Improvements
Sub-function 5 Organization and Support	Structure and Support	Planning and Control	Productivity Effectiveness	Quality
Sub-function 6 Administration and Supply	Economics	Budget and Control	Outsourcing Services	Materials and Spare Parts
Information Communication Technology, Enabling technologies	Management	Administration and Supply	Organization and Support	Engineering

Tab. 3.1: Haupt- und Unterbereiche der EN-Norm *Maintenance – Maintenance Key Performance Indicators* (vgl. CEN 2007, S. 7)

Aufgrund ihrer Verbreitung wurde die EN-Norm in der Fassung von 2019 als Grundlage für die Klassifizierung von Datenprodukten gewählt.

3.4 Bewertungsmodell

Damit die Relevanz der Datenprodukte in Form einer Priorisierung innerhalb eines Organisationskontextes bewertet werden kann, müssen multiple Kriterien berücksichtigt werden. Je nach Organisationsstruktur können diese Kriterien und deren Gewichtung stark voneinander abweichen. Für diese Bewertung können drei verschiedene Verfahren genutzt werden:

- Bei fehlenden Vergleichswerten kann eine Bewertung durch Anwendende als Expert*innen auf Basis von Verhältniszahlen durchgeführt werden (vgl. Kordon 2020, S. 59).
- Eine Möglichkeit besteht dabei in einer Bewertung anhand realer Kosten und Nutzen in Euro, die hier nicht betrachtet wird.
- Eine Nutzwertanalyse kann durchgeführt werden, wenn ein Pool von Spezialist*innen für die Überprüfung zur Verfügung steht.

Nutzwertanalysen bieten eine Möglichkeit, multivariate Entscheidungen (oder Multi-Criteria Decision Analysis) durch das Aufteilen von Entscheidungsalternativen in bewertbare Kriterien zu unterstützen (vgl. Kühnapfel 2019, S. 1). Sie bieten ein Rahmenwerk, um Handlungsalternativen zu bewerten. Nutzwertanalysen sind ein Teil der *Multi-Criteria Decision Analysis*, die sich, wie in der Tab. 3.2 dargestellt, einteilen lassen (vgl. Geldermann und Lerche 2014, S. 10 f.; Zimmermann und Gutsche 1991, S. 27).

Multi-Criteria Decision Analysis		
Multi-Objective Decision Making	Multi-Attribute Decision Making	
Vektoroptimierung Zielprogrammierung Anspruchsniveau ...	Klassische Ansätze: Nutzwertanalyse Analytic Hierarchy Process (AHP) ...	Outranking-Ansätze: Elimination Et Choice Translation Realty (ELECTRE) Preference Ranking Organization METHod for Enrichment Evaluations (PROMETHEE) ...

Tab. 3.2: Exemplarische multivariater Entscheidungsunterstützungsmethoden (vgl. Zimmermann und Gutsche 1991, S. 27)

Multi-Objective Decision Making legt den Fokus darauf, eine optimale Lösung zu einem Entscheidungsproblem zu finden; Multi-Attribute Decision Making hat hingegen einen Schwerpunkt auf der Bewertung von Handlungsalternativen (vgl. Alinezhad und Khalili 2019, S. XV). Bei diesen Methoden wird zudem nach klassischen Ansätzen wie der Nutzwertanalyse und nach Outranking-Ansätzen wie ELECTRE oder PROMETHEE unterschieden (vgl. Geldermann und Lerche 2014, S. 11). Traditionelle Verfahren bewerten Nutzenfunktionen, um den Präferenzen der Anwendenden Nutzenwerte zuzuweisen (vgl. Geldermann und Lerche 2014, S. 11). Hierbei werden Variablen definiert und als Teilnutzenwerte bewertet, aus denen ein Gesamtnutzenwert abgeleitet werden kann. Outranking-Ansätze können als *französische Schule* bezeichnet werden; im Ergebnis werden Rangfolgen der Entscheidungsalternativen erstellt (vgl. Geldermann und Lerche 2014, S. 12). Abweichend von den klassischen Ansätzen werden bei den Outranking-Ansätzen Präferenzwerte durch „paarweise Vergleiche“ ermittelt (Geldermann und Lerche 2014, S. 13). Dies ermöglicht, verschiedene Präferenzwerte und Wechselwirkungen zwischen Variablen aufzudecken. Im Weiteren wird erläutert, weshalb für diese Arbeit die Nutzwertanalyse gewählt wurde.

Das Einsatzspektrum der Nutzwertanalyse ist breit und sie eignet sich auch für „schwer quantifizierbare“ Alternativen, etwa aus dem „Technologie-, Forschungs-, Entwicklungs- und Innovationsmanagement“ (Nagel et al. 2020, S. 55). Die Nutzwertanalyse ist eine mehrdimensionale semiquantitative Methode zur Entscheidungsunterstützung (vgl. Heesen 2009, S. 111). Da hierbei nicht quantifizierbare Entscheidungskriterien einbezogen werden können, wird sie auch als qualitative Methode bezeichnet (vgl. Nagle und Sammon 2017, S. 54). Das Ziel der Nutzwertanalyse ist die Bewertung verschiedener Optionen in Form einer Rangfolge basierend auf individuellen Bedürfnissen und Präferenzen (vgl. Nagel et al. 2020, S. 54). Dieser individuelle Einfluss kann zu unterschiedlichen Reihenfolgen führen (vgl. Nagel et al. 2020, S. 55). Gleichwohl wird so auch ein kritischer Diskurs über die verwendeten Auswahlkriterien ermöglicht. Aus diesem Grund wurde die Nutzwertanalyse als Basis für die Priorisierung der Datenprodukte bezogen auf den Nutzen und den Implementierungsaufwand der Datenanalyse gewählt.

Die Einführung der Nutzwertanalyse im deutschen Sprachraum erfolgte 1971 und geht auf Zangemeister zurück (vgl. Hanusch 2011, S. 283). Bei der Nutzwertanalyse steht das Ranking von Handlungsalternativen im Vordergrund, Kosten können als „negative Teilnutzen“ berücksichtigt werden (Hanusch 2011, S. 175). Innerhalb der Nutzwertanalyse werden folgende Vorgehensschritte veranschaulicht (vgl. Hanusch 2011, S. 203 f.):

Zielanalyse: Zunächst wird ein *projektspezifisches Zielsystem* (Z_j) definiert:

Zielsystem (Z_j):

$$Z_j (j = 1, \dots, m)$$

Erfassung von Nebenbedingungen: Hierbei geht es um die Definition und Bestimmung verschiedener relevanter Bewertungsvariablen.

Bestimmung von Alternativen (A_i): Hierbei werden verschiedene Alternativen (hier: Datenprodukte) bestimmt, die später in einer Rangfolge klassifiziert werden können.

Alternativen (A_i):

$$A_i (i = 1, \dots, n)$$

Wirksamkeitsmaß (W_{ij}): Bei dieser Stufe werden geeignete Teilwirksamkeiten oder Zilerträge quantitativ ermittelt.

Wirksamkeitsmaß (W_{ij}):

$$w_{ij} (i = 1, \dots, n; j = 1, \dots, m)$$

Ermittlung der Zielerfüllungsgrade (e_{ij}): Hierbei werden die Teilwirksamkeiten der Handlungsalternativen zu einer Gesamtwirksamkeit der Handlungsalternativen zusammengefasst. Voraussetzung ist eine gleiche Skalierung der Teilwirksamkeiten (vgl. Zangemeister 2014, S. 333). Um

diese Skalierung zu erreichen, muss ein Bewertungsschlüssel definiert werden, z. B. 1–5, 1–10 oder 1–100 Punkte. Durch diese vereinfachte Transformation auf eine einheitliche Skalierung werden Vergleich und Bewertung des Gesamtnutzens möglich (vgl. Hanusch 2011, S. 177).

i **Zielerfüllungsgrade (e_{ij}):**

$$e_{ij} = (i = 1, \dots, n; j = 1, \dots, m)$$

Bewertung von Zielgewichten (g_j) und Teilnutzenwerten (n_{ij}).

i **Zielgewichte (g_j) und Teilnutzenwerte (n_{ij}) (siehe Formel 3.1):**

$$g_j (j = 1, \dots, m)$$

$$n_{ij} = g_j \times e_{ij} \quad (3.1)$$

Entscheidung, indem auf Basis der Gesamtnutzwerte (3.2) eine Rangordnung abgeleitet wird.

i **Gesamtnutzenwerte (N_j) (siehe Formel 3.2):**

$$N_j = \sum_{i=1}^m n_{ij} \quad (3.2)$$

Zu 1. Um eine klare projektspezifische Priorisierung zu erreichen, wurden zwei Hauptfaktoren als wesentlich für die Zielerreichung des Forschungsprojekts *WiSA Big Data* identifiziert: die Wertschöpfung einer Datenanalyse für die Forschungs- und Industriepartner sowie der Implementierungsaufwand der Methoden zur Datenanalyse für die Forschungspartner. In der Studie *Ten red flags signaling your analytics program will fail* von McKinsey werden die Durchführbarkeit (*Feasibility*) und die Wirkung (*Impact*) gegenübergestellt (vgl. Fleming et al. 2018). Angelehnt an diese Priorisierungsmethode werden in dieser Arbeit zum einen der Implementierungsaufwand und zum anderen die Wertschöpfung für ein initiales Ranking der Datenprodukte genutzt.

Nachdem die 12 für das Forschungsprojekt relevantesten Datenprodukte identifiziert und die Ambitionslevel festgelegt waren, konnte im nächsten Schritt das Ranking mit den Forschungs- und Industriepartnern erfolgen (siehe Abb. 3.3).

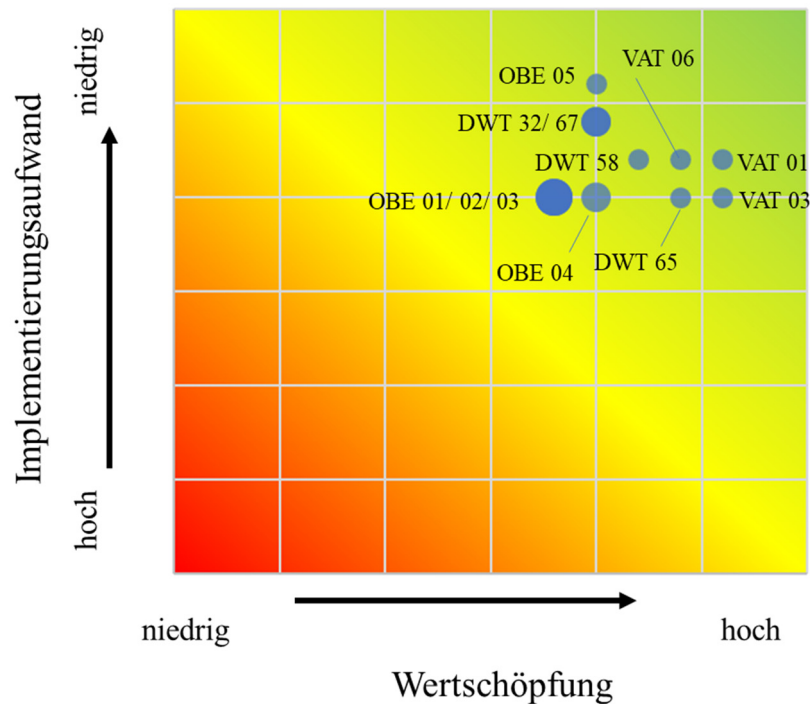


Abb. 3.3: Übersicht der Datenprodukte mit der höchsten Priorität

Im Anschluss wurden die Top-12-Datenprodukte (siehe Abb. 3.3) in einem Workshop verfeinert. Nach dieser erfolgreichen Priorisierung der Kernfragen mussten die Datenprodukte innerhalb der Geschäftsprozesse und des Entscheidungsumfelds durch das Datenwertschöpfungsketten-Canvas kontextualisiert werden.

Zu 2. Zwei Nebenbedingungen – die Wertschöpfung und der Implementierungsaufwand – wurden zur Bewertung der Priorität identifiziert. Die erste Nebenbedingung bestand in der Bewertung der Wertschöpfungen durch die Forschungs- und Industriepartner. Hierbei lautete die Frage, ob ein Datenprodukt vorhanden oder gewünscht ist. Für den Implementierungsaufwand wurden der Aufwand der Datenaufbereitung, die Möglichkeit, eine einfache statistische Auswertung durchzuführen, der Aufwand der Methodenumsetzung sowie der Projektfokus der Fragestellung als Nebenbedingungen bestimmt.

Zu 3. Bestimmung von Alternativen: Hierbei geht es um die verschiedenen Datenprodukte als Entscheidungsalternativen. Die Datenwertschöpfungskette ist eng mit der Beantwortung der relevanten Datenprodukte oder Fragestellungen durch Analytik verbunden. Fragen können so als „Artefakte der Neugier“ bezeichnet werden (Seliya et al. 2019, S. 2). Fragen eignen sich somit auf der einen Seite dazu, den aktuellen Status quo zu hinterfragen. Auf der anderen Seite können Fragen gestellt werden, die bisher in der Organisation noch nicht oder nur mit erheblichem Aufwand beantwortet werden können. Um sowohl vorhandene als auch gewünschte Datenprodukte zu identifizieren, wurde QuestionStorming als Methode zur Erhebung von Datenprodukten gewählt.

Zu 4. und 5. Im nächsten Schritt wurde die Wertschöpfung für das Projekt von jedem einzelnen Industriepartner bewertet. Dabei wurde eine einfache Ordinalskala von 1 (rot: entsprechend nicht relevant oder gewünscht) über 2 (gelb: entsprechend vielleicht, relevant oder gewünscht) bis 3 (grün: entsprechend voll relevant oder gewünscht) verwendet. Als Gewichtung wurden den Bewertungen der einzelnen Industriepartner jeweils 20 % zugestanden, da es sich um ein anwendungsnahes Forschungsprojekt handelt. Zusätzlich wurde die Nebenbedingung, ob das Datenprodukt bereits vorhanden ist (1) oder von den Industriepartner*innen gewünscht ist (2), mit 20 % bewertet. Da es sich hierbei um ein nachgelagertes Ziel handelt, wurden lediglich zwei Auswahlmöglichkeiten geboten. Weitere 20 % der Gewichtung wurden der Bewertung der Wertschöpfung durch die gesammelten Forschungspartner beigemessen.

Zu 6. Nachdem die einzelnen Projektpartner der Forschungs- und Industrieseite ihre individuellen Bewertungen abgegeben hatten (siehe Tab. 3.3 für ein Beispiel), wurden diese Bewertungen mit den entsprechenden Gewichtungen multipliziert. Im Ergebnis konnten so Teilnutzen in Form einer Gesamtwertschöpfung sowie eines Gesamtimplementierungsaufwandes definiert werden.

ID	Wertschöpfung					Implementierungsaufwand			
	Evaluation DWT	Evaluation VAT	Evaluation OBE	Existing (1) vs wished (2)	Rating research	Effort data preparation	Possible quick wins with simple statistics on the data (priority AP2)	Effort method implementation	Project focus according to question
	20%	20%	20%	10%	30%	20%	20%	20%	40%
VAT03	✓	✓	●	●	✓	●	✗	✗	✓

Tab. 3.3: Zielesertrags-Matrix

Zu 7. Da die Wertschöpfung und der Implementierungsaufwand in diesem Vorgehen gleich bewertet wurden, ergab sich die im Weiteren beschriebene Formel (3.3).



Gesamtnutzwert (N_j) (siehe Formel 3.3):

Hierbei werden die Summe der Wertschöpfungsbewertungen und die Summe der Bewertungen des Implementierungsaufwands zum Quadrat addiert und im Anschluss wird die Wurzel daraus gezogen.

$$N_j = \sqrt{n_{ij}(\text{Wertschöpfung})^2 + n_{ij}(\text{Implementierungsaufwand})^2} \quad (3.3)$$

Durch die Bewertung der Gesamtnutzenwerte kann eine Priorisierung stattfinden, die aufgrund der hohen Anzahl an Fragestellungen in *WiSA Big Data* notwendig war.

3.5 Datenwertschöpfungsketten-Ontologie

Der Aufbau einer Ontologie ist ein mehrstufiger Prozess (vgl. Noy und McGuinness 2001, S. 5 ff.; Stuckenschmidt 2011, S. 157). Der Erstellungsprozess kann analog zu Peffers et al. *Design Science Research Methodology*-Prozess beschrieben werden (vgl. Peffers et al. 2007, S. 54). Der Prozess beginnt mit der Bestimmung des Problems, dem dahinterstehenden Motiv, der Problembeschreibung sowie der Abgrenzung des Problems. In dieser Phase des Prozesses werden sowohl der Anwendungsbereich als auch das Untersuchungsfeld für eine Ontologie festgelegt. Im Anschluss daran werden relevante Begriffe definiert. In der darauffolgenden Phase werden sowohl das Ziel der Ontologie als auch die Lösung, wie die Ontologie umgesetzt werden soll, spezifiziert. Die Nützlichkeit derzeit verwendeter Ontologien wird in Bezug auf das Ziel der Forschung bewertet. Daran schließt sich die Phase der Entwicklung von Artefakten an. Um dieses Ziel zu erreichen, werden die Klassenhierarchie, die Instanzen und die Beziehungen definiert. Die Demonstrationsphase umfasst neben der Analyse und Überprüfung der Ontologie auch die Untersuchung, ob *Ontologie-Patterns* implementiert werden können. Die Evaluierungsphase besteht aus einer Bewertung der Ergebnisse (z. B. Inferenz- oder Konsistenzprüfungen). In diesem Zusammenhang kann die Ontologie beispielsweise auch für Fallstudien verwendet werden. In der Kommunikationsphase werden die Ergebnisse diskutiert und ggf. die Visualisierungen von Ontologien zur Veranschaulichung genutzt.

Für die Schärfung des Detaillierungsgrades wurde das BMC (vgl. Osterwalder et al. 2010, S. 16 ff.) erweitert. Im letzten Kapitel wurden die Ergänzungen des BMC erläutert. Bei Kick-off-Veranstaltungen wurde das BMC den Industriepartnern präsentiert, diskutiert und ausgefüllt. Die Ergebnisse aus der Priorisierung der Datenprodukte und der optionalen Detaillierung über das BMC fließen in die finale Auswertung und Visualisierung ein.

Das BMC stellt eine etablierte Möglichkeit dar, Datenprodukte in einem Geschäftsmodell zu untersuchen und abzubilden (vgl. Haneke 2019, S. 52; Kruse et al. 2018, S. 10; Osterwalder et al. 2010, S. 50). Neben der wissenschaftlichen Basis des BMC verweist Haneke für datenzentrierte Geschäftsmodelle auf eine Arbeit von Tempichs und Riegers (vgl. Haneke 2019, S. 52). In diesem Paper wird am Beispiel der Telekommunikationsindustrie auf die Notwendigkeit hingewiesen, die

Datenwertschöpfungskette zu analysieren, um datenzentrierte Geschäftsmodelle zu entwickeln sowie deren Risiken und Chancen zu bewerten (vgl. Tempich und Rieger 2007, S. 3).

Die Struktur der BMC-Ontologie ist in Abb. 3.4 visualisiert (vgl. Osterwalder 2004, S. 104). Das (Daten-)Produkt interagiert mit dem Infrastrukturmanagement, den Kundenschnittstellen und den finanziellen Aspekten als den Säulen des BMC; auf der nächsten Ebene formen sich Elemente, die den einzelnen Säulen zugeordnet sind. Das ursprüngliche BMC besteht aus neun Elementen, wobei sich das Wertversprechen im Mittelpunkt befindet (vgl. Osterwalder et al. 2010, S. 16 ff.; Osterwalder 2004, S. 107). Datenprodukte sind das Wertversprechen an die Kundensegmente (Stakeholder oder Anwendende), für sie relevante Fragestellungen mithilfe von Datenanalysen zu beantworten. Schlüsselpartner*innen müssen Schlüsselaktionen durchführen und dabei Schlüsselressourcen wie Datenquellen nutzen (vgl. Osterwalder et al. 2010, S. 36). Das Infrastrukturmanagement (linke Seite von Abb. 3.4) befasst sich mit erforderlichen Ressourcen, Fähigkeiten oder notwendigen Partnerschaften. Kundenschnittstellen (auf der rechten Seite von Abb. 3.4) definieren, wie das Wertversprechen mit der Klientel in *Beziehung* tritt und über welche Kanäle es die Kund*innen erreicht. Kostenstruktur und Umsatzströme bilden die unteren Felder des BMC.

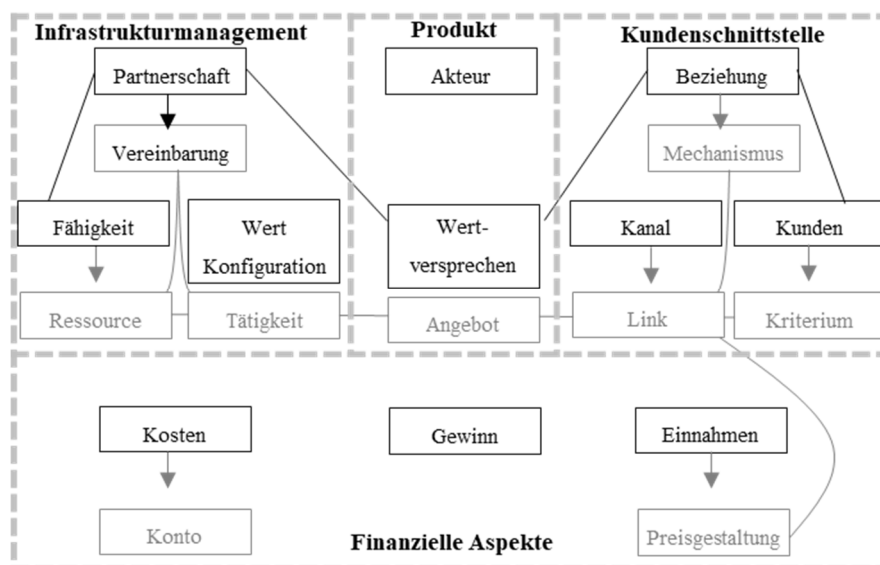


Abb. 3.4: BMC-Ontologie (vgl. Osterwalder 2004, S. 44)

Zu Beginn werden Tabellen mit einzelnen Elementen, der Verknüpfung mit anderen Elementen, der Kardinalität, den Attributen und möglichen Referenzen definiert (siehe Tab. 3.4) (vgl. Osterwalder 2004, S. 47).

Name des Elements	Name
Definition	Liefert eine genaue Beschreibung des Geschäftsmodellelements
Teil von	Legt fest, zu welcher Säule der Ontologie das Element gehört oder von welchem Element es ein Unterelement verkörpert
Verwandt mit	Beschreibt, mit welchen anderen Elementen der Ontologie ein Element in Beziehung steht
Unterelemente	Gibt an, in welche Unterelemente ein Element zerlegt werden kann
Kardinalität	Legt die Anzahl der zulässigen Vorkommen eines Elements oder Unterelements innerhalb der Ontologie fest
Attribute	Listet die Attribute des Elements oder Unterelements auf; die zulässigen Werte eines Attributs werden zwischen den Akzenten {VALUE1, VALUE2} angegeben, ihr Vorkommen wird in Klammern angegeben (z. B. 1n). Jedes Element und Unterelement hat zwei Standardattribute, nämlich NAME und BESCHREIBUNG, die eine Kette von Zeichen enthalten {abc}.
Referenzen	Gibt die relevantesten Referenzen in Bezug auf das Geschäftsmodellelement an

Tab. 3.4: Elemente eines Geschäftsmodells (vgl. Osterwalder 2004, S. 47)

Im Feld *Kundenbeziehung* geht es darum, zu verstehen, wie das Produkt mit der Klientel in Beziehung tritt. Hier kann beispielsweise ein Reporting genannt werden, bei dem die Zielgruppe regelmäßig automatisch informiert wird. Die Vertriebskanäle als weiterer Punkt zielen darauf ab, herauszuarbeiten, wie das Datenprodukt zur Zielgruppe gelangt, also beispielsweise wo (Dashboard) bzw. wie (Visualisierung, Report) die Ergebnisse für die Zielgruppe dargestellt werden. Das letzte externe Feld widmet sich einer klaren Definition der Zielgruppe: Wer entscheidet/reagiert am Ende aufgrund des Analyseergebnisses eines Datenprodukts? Die unteren Felder des BMC sind die Kostenstruktur und die Einkommensquellen. Bei der Kostenstruktur werden alle für das Datenprodukt ausschlaggebenden Kosten bewertet. Die Einkommensquellen bilden sämtliche Möglichkeiten ab, bei denen durch das Datenprodukt Gewinne erzielt werden können. Hier ist bei Datenprodukten als Insights beispielsweise zu bewerten, ob und in welcher Höhe Datenprodukte zu einer Kostenreduktion beitragen können.

Das BMC kann für Datenprodukte verwendet werden, da sein Hauptziel darin besteht, beliebige Wertversprechen oder Produkte in einem Wertschöpfungskontext einer Organisation zu beschreiben. Bezogen auf Datenprodukte wurde die Definition der verschiedenen Elemente neu gewählt und durch eine Literaturrecherche um zusätzliche Punkte sowie Unterpunkte ergänzt. Das neu erstellte Modell wird in dieser Arbeit als Datenwertschöpfungsketten-Canvas bezeichnet. Alle Säulen und Elemente wurden codiert, um eine Weiterverarbeitung im Evaluationsprozess zu ermöglichen. Im Zentrum steht dabei die Wertschöpfung aus Daten innerhalb einer Organisation. Ein Datenprodukt

muss einen Mehrwert für die Zielgruppe generieren. Im Falle eines Datenprodukts kann dies etwa die Datenaufbereitung oder die Durchführung einer Datenanalyse beinhalten. Im Weiteren werden die Schlüsselressourcen betrachtet; diese können physische, aber auch finanzielle Ressourcen umfassen. Am Beispiel eines Datenprodukts kann es sich dabei etwa um die Datenquellen, die Datenspeicherung oder die Datenaufbereitung als Ressource für eine Datenanalyse handeln. Im Bereich der Schlüsselpartner steht im Fokus, wer bei der Erstellung oder Bearbeitung der Datenprodukte unterstützt: Gibt es z. B. externe oder interne Dienstleistende zur Datenauswertung oder müssen die Daten von bestimmten Personen innerhalb oder außerhalb der Organisation vorbereitet oder ausgewertet werden?

Die Literaturrecherche erfolgte deduktiv-induktiv. Die deduktive Codierung wurde im ersten Schritt aus Übersichtsstudien abgeleitet. Zunächst wurden Quellen und Schlüsselwörter anhand artverwandter Vorarbeiten ermittelt, die sich mit Datenprodukten allgemein (vgl. Haneke 2019; Hötzl 2022; Kruse et al. 2018) oder mit Datenprodukten innerhalb der Anwendungsdomäne Offshore-Wind beschäftigt haben (vgl. Bendlin et al. 2019, S. 6 f.; Seyr und Muskulus 2019, S. 4 f.). Die detaillierte Codierung findet sich in Anhang D.

Um die Übertragbarkeit des BMC auf die vorliegende Arbeit zu vereinfachen, werden die ursprünglich geprägten Grundbegriffe (vgl. Osterwalder et al. 2010, S. 16 ff.) angepasst. *Kund*innen* (Customer) werden zu Anwendenden und der Begriff *Wertangebot* (Value Proposition) bezieht sich auf ein Datenprodukt. So finden sich auf der rechten Seite des Datenwertschöpfungsketten-Canvas die Wertschöpfung für die Endanwendenden, die Interaktion mit den Zielgruppen und die ggf. daraus resultierenden Einnahmequellen oder Kosten- bzw. Risikoreduktion. Die Interaktion innerhalb des Datenwertschöpfungsketten-Canvas wird durch Kanäle (Kommunikationskanäle, Vertriebskanäle, Schnittstellen von Anwendenden) und Beziehungen von Anwendenden definiert. Bei der Beziehung der Anwendenden geht es darum, welche Beziehung Erstellende eines Datenprodukts mit den Anwendenden aufbauen bzw. unterhalten möchten. Auf der linken Seite des Datenwertschöpfungsketten-Canvas befindet sich der Prozess der Wertschöpfung inklusive der benötigten (internen und externen) Partner*innen und der damit einhergehenden Kostenstrukturen. Der Aufbau nach Osterwalder wurde in Abb. 3.5 ergänzt um die in der initialen Literaturrecherche identifizierten Elemente.

Schlüsselpartner*innen Welche Partner*innen wirken bei der Erarbeitung und der kontinuierlichen Bereitstellung mit? SP1 Interne und externe Partner*innen? SP2 Wie wird unterstützt? SP3 Welche Rolle hat der*die Partner*in im Data-Science-Team?	Schlüsselaktivitäten Welche Aktivitäten müssen innerhalb der Datenprodukterstellung ausgeführt werden? SA1 Problemstellung SA2 Datenerhebung? SA3 Analysemethoden/Modellauswahl SA4 Datenvorbereitung SA5 Modellaufbau (Trainieren/Testen) SA6 Datenanalyse und Ergebnis (KPIs) Schlüsselressourcen Was ist notwendig, um das Datenprodukt aufzusetzen und kontinuierlich bereitzustellen sowie zu nutzen? SR1 Erforderliche Ressourcen? SR2 Erforderliche Datenquellen? SR3 Beeinflussende Randbedingungen?	Wertschöpfung Welchen Wert hat das Datenprodukt (potentiell)? WS1 Welchen Wert hat diese Entscheidung bzw. die Verbesserung monetär? WS2 Welche Entscheidung ermöglicht das Datenprodukt? -> Verknüpfung zu ZG3 WS3 Welche nicht funktionalen Anforderungen bestehen?	Kundenbeziehung In welcher Beziehung steht der*die Data Scientist*in zum*zur Nutzer*in des Datenprodukts? KB1 Beziehung DP <> Beteiligte (Feedback Prozess)? KB2 Relevanter Prozessschritt für das DP? KB3 Akzeptanzkriterien für das Ergebnis? Kanäle In welchem Format und welcher Frequenz wird das Datenprodukt final kommuniziert? KA1 Nutzungshäufigkeit? KA2 Gebrauchsform DP? KA3 Visualisierung? (von SA6)	Zielgruppen Wer soll das Datenprodukt im Unternehmen nutzen? ZG1 Wer wird informiert? Wem hilft das DP? ZG2 Wer entscheidet? Wer ist der*die Endnutzer*in? ZG3 Anwender*innenbericht: Als ... [wer] möchte ich .. [was] wissen, um ... zu entscheiden [warum].
Kostenstruktur Welche Kosten sind mit der Bereitstellung des Datenproduktes verbunden? KS1 Wie hoch sind die Kosten/ der Aufwand, um das Analyseergebnis des Datenproduktes zu generieren? (incl. CAPEX für Messgeräte z. B.) KS2 Wie hoch sind die Risiken des betrachteten Vorgangs?		Einkommensquellen Welcher Nutzen kann aus der Anwendung des Datenproduktes gezogen werden? Wie hoch ist dieser Wert? ES1 Welches Einkommen/ Welche Kosteneinsparungen können durch das Datenprodukt erreicht werden? ES2 Datenwert		

Abb. 3.5: Erweitertes initiales Business Model Canvas

Diese erste Codierung wurde durch eine induktive Literaturrecherche erweitert. Bei der induktiven Erweiterung wurde eine breitere Palette von Variablen definiert, die durch Interviews mit Expert*innen geprüft wurden. Die Untersuchung ergab, dass lediglich ein Bruchteil der Variablen genutzt wurde. Diese Befragungsergebnisse sorgten für eine Verdichtung der Variablen, was die Verständlichkeit und die Übertragbarkeit des Modells verbesserte. Dieses iterative Vorgehen folgt den Rigor-Kreisen (vgl. Hevner Alan 2007, S. 88). Daher erscheint es sinnvoll, die Variablen nach Bedarf zu nutzen und je nach Anwendung zu minimieren oder zu erhöhen. Ausgehend von der Überlegung, nur die relevantesten Elemente zu verwenden, mussten Elemente in sieben von 12 Datenprodukten genutzt werden (siehe Tab. 3.5).

Element	Code	Kernfragen zum Datenprodukt	SUMME
Schlüsselressourcen	SR2	Datenquellen?	11
Wertschöpfung	WS1	Welchen Wert hat diese Entscheidung monetär?	11
Zielgruppen	ZG1	Wer wird informiert? Wem hilft das Datenprodukt?	11
Kundenbeziehung	KB3	Akzeptanzkriterien für das Ergebnis?	10
Kanäle	KA1	Frequenz der Nutzung?	10
Kanäle	KA2	Gebrauchsform Datenprodukt?	10
Zielgruppen	ZG2	Wer entscheidet? Wer sind Endanwendende?	10
Zielgruppen	ZG3	Bericht der Anwendenden – Wer macht was?	10
Wertschöpfung	WS2	Welche Entscheidung verbessert/ermöglicht das Datenprodukt?	9
Prozesse	PR1	Muss ein neuer Prozess definiert werden oder wird es in einen bestehenden Prozess eingebunden?	8
Schlüsselpartner*innen	SP1	Interne und externe Partner*innen?	8
Schlüsselpartner*innen	SP2	Wie wird unterstützt?	7
Kanäle	KA3	Visualisierung?	7

Tab. 3.5: Reduzierte Codierung als BMC-Input

Als Limitierung ist zu betrachten, dass die Industriepartner von *WiSA Big Data* lediglich 12 Datenprodukte mit dem ersten Datenwertschöpfungsketten-Canvas ausgefüllt haben. Dementsprechend können diese Antworten lediglich indikativ genutzt werden, um die Elemente des Modells zu reduzieren; dabei waren die Kostenstruktur und die Einkommensquellen ausgeklammert, da diese als Teil des Kennzahlensystems später beschrieben werden.

Auf Grundlage einer Literaturrecherche wird eine Ontologie für Datenwertschöpfungsketten erstellt. Da Datenwertschöpfung breit definiert sein kann, erfolgt eine Beschränkung auf Canvas-Modelle, die auf der BMC-Ontologie (vgl. Osterwalder 2004, S. 104) beruhen. Aus den Ergebnissen dieser Suchalgorithmen wurden die Kategorien A, B und C gebildet (vgl. Hay et al. 2017, S. 3 f.). Die Suchergebnisse in den einzelnen Online-Datenbanken, die relevanten Veröffentlichungen (A, B) sowie die Suchmethode sind in Tab. 3.6 aufgeführt. Wegen ihrer Größe wurden fünf Online-Bibliotheken unter *Sonstige* zusammengefasst (HBR, MDPI, SAGE-Journals, Wiley Online Library und Google Scholar).

Nach der Festlegung der ersten Codierung aus den Vorarbeiten erfolgte die erweiterte Literaturrecherche. Um die Suchergebnisse zu verbessern, wurden zahlreiche Algorithmen entwickelt (siehe Tab. 3.6).

Bibliothek	Insgesamt [A, B, C]	Relevant [A, B]	Suchalgorithmus
IEEE Xplore einschließlich IET	233	7	((("Alle Metadaten":Geschäftsmodell) OR ("Alle Metadaten":Big Data) OR ("Alle Metadaten":KI) OR ("Alle Metadaten":Data Science) OR ("Alle Metadaten":Datenprodukt) OR ("Alle Metadaten": Forschungsprojekt)) AND ("Alle Metadaten":Canvas))
ACM Digitale Bibliothek	84	3	[[Alle: "Business Model Canvas"]] OR [[Alle: "ai canvas"]] OR [[Alle: "Data Science canvas"]] OR [[Alle: "big data canvas"]] OR [[Alle: "data product canvas"]] OR [[Alle: "research project canvas"]]
Springer Link	36	4	Anpassung nicht erforderlich
Science Direct	583	6	((("Data Science") OR ("Big Data") OR ("Datenprodukt"))) AND "Canvas")
AISeL	434	6	("Business" AND "Model") OR ("KI") OR ("Daten" AND "Wissenschaft") OR ("Big" AND "Daten") OR ("Daten" AND "Produkt") OR ("Forschung" AND "Projekt") AND "Canvas")
Andere (z. B. MDPI, Wiley)	199	10	Individuelle Anpassung erforderlich
Insgesamt	1579	36	-

Tab. 3.6: Angewandte Suchalgorithmen (vgl. Bendlin et al. 2024, S. 82)

Im Ergebnis wurden 13 A-Quellen identifiziert und zur Erstellung der Ergebnisse herangezogen. Diese Quellen lieferten 21 Canvas-Modelle, die in Tab. 3.7 dargestellt sind.

Element	Kundenschnittstelle			(Daten) Produkt	Infrastruktur Management										Finanzielle Aspekte																
	KB1	KB2	KB3	KA1	KA2	KA3	ZG1	ZG2	ZG3	WS1	WS2	WS3	SA1	SA2	SA3	SA4	SA5	SA6	SA7	SR1	SR2	SR3	SP1	SP2	SP3	SP4	KS1	KS2	ES1	ES2	
Wie ist die Beziehung der Nutzer mit dem Datenprodukt																															
Was sind die Prozessschritte zur Erstellung des Datenprodukts?																															
Wie sind die Akzeptanzkriterien für das Ergebnis?																															
Wie häufig wird das Datenprodukt genutzt?																															
In welcher Form wird das Datenprodukt genutzt?																															
Wie wird das Datenprodukt visualisiert (Data Storytelling)?																															
Wer wird informiert? Wem hilft das Datenprodukt?																															
Wer entscheidet? Wer ist der Endnutzer?																															
User Story - Wer macht was?																															
Was ist der (monetäre) Wert (Proposition) der Datenanalyse/Entscheidung?																															
Welche Entscheidung verbessert/ermöglicht das Datenprodukt?																															
Was sind die Anforderungen (nicht-funktional) an das Datenprodukt?																															
Wie ist die Problemdarstellung (Anforderung) aus Nutzersicht?																															
Gibt es Anforderungen an Datenintegration?																															
Welche Datenanalysemethoden und Modelle werden genutzt?																															
Wie findet die Datenerfassung statt?																															
Wie findet die Modellkonstruktion statt (trainieren und testen)?																															
Wie werden die Daten aufbereitet?																															
Wie werden die Ergebnisse der Datenanalyse genutzt (KPIs)?																															
Welche Ressourcen werden für die Datenanalyse benötigt?																															
Welche Datenquellen werden für die Datenanalyse benötigt?																															
Welche Randbedingungen können die Datenanalyse beeinflussen?																															
Welche internen/externen Partner benötigt die Erstellung des Datenprodukts?																															
Wie wird die Unterstützung geleistet?																															
Welche Rolle (Fähigkeiten) hat der Partner im Data Science Team?																															
Welche Software wird für die Erstellung der Datenprodukte benötigt?																															
Wie hoch sind die Kosten/Aufwand, der Datenanalyse?																															
Welche Risiken/Herausforderungen könnten bei dem Datenprodukt auftreten?																															
Welche Einnahmen/ Kosteneinsparungen können erzielt werden?																															
Wie hoch ist der Datenwert?																															
Canvas	KB1	KB2	KB3	KA1	KA2	KA3	ZG1	ZG2	ZG3	WS1	WS2	WS3	SA1	SA2	SA3	SA4	SA5	SA6	SA7	SR1	SR2	SR3	SP1	SP2	SP3	SP4	KS1	KS2	ES1	ES2	
[1]																															
[2]	X	X					X	X		X					X	X				X	X		X					X		X	
[3]											X			X	X	X			X		X	X									
[4]	X	X					X	X	X					X	X	X							X	X	X	X	X				
[5]	X	X									X													X							
[6]										X	X			X	X	X															X
[7]				X																				X							
[8]	X																					X		X							
[9]	X						X	X	X	X	X	X		X		X		X	X	X		X	X	X					X		
[10]	X				X	X				X	X	X			X	X						X	X	X					X		
[11]	X									X						X					X	X	X				X		X		
[12]			X			X					X		X	X	X	X	X	X	X	X	X	X				X	X	X	X	X	X
[13]																															
[14]	X				X	X		X						X	X	X			X	X		X						X	X	X	X
[15]																															
[16]	X	X	X				X				X	X		X	X	X	X	X	X	X	X	X	X								
[17]	X	X	X				X	X	X		X	X	X		X							X	X	X	X	X	X		X		
[18]	X					X					X			X	X	X							X	X	X				X		
[19]										X	X				X	X	X					X		X							
[20]										X	X				X	X							X						X	X	
[21]					X					X			X					X	X	X			X	X			X	X	X	X	X
Σ*	50%	23%	14%	5%	14%	18%	23%	23%	14%	36%	55%	18%	14%	36%	55%	64%	23%	36%	32%	23%	23%	27%	45%	14%	14%	18%	27%	23%	18%	14%	
Σ**	18%	55%	91%	91%	91%	64%	100%	91%	91%	100%	82%	27%	55%	0%	36%	36%	9%	9%	27%	45%	100%	55%	73%	64%	36%	0%	27%	0%	55%	18%	
Σ	34%	39%	52%	48%	52%	41%	61%	57%	52%	68%	68%	23%	34%	18%	45%	50%	16%	23%	29%	34%	80%	41%	59%	39%	25%	9%	27%	11%	37%	16%	

*Häufigkeit in der Literaturrecherche, **Häufigkeit der Nutzung innerhalb der Workshops

[1] AI Canvas (vgl. Agrawal et al. 2018); [2] AI Project Canvas (vgl. Zawadzki 2019); [3] Analytics Canvas (vgl. Kühn et al. 2018, S. 165); [4] Big Data Management Canvas (vgl. Kaufmann 2019, S. 8); [5] Business Process Canvas (vgl. Koutsopoulos und Bider 2018, S. 4); [6] Data Insight Generator (vgl. Kühne und Böhmann 2019); [7] Data Canvas (vgl. Mathis und Köbler 2018, S. 319); [8] Data Collection Map (vgl. Kayser et al. 2019, S. 8); [9] Data Innovation Board (vgl. Kronsbein und Mueller 2019, S. 565); [10] Data Product Canvas (vgl. Fruhwirth et al. 2020, S. 523); [11] Data Project Canvas (vgl. Kolkman und Sneep 2019, S. 5); [12] Data-Science Workflow Canvas (vgl. Vasandani 2019); [13] Data Service Card (vgl. Breiffuss et al. 2020, S. 608); [14] Data Value Map (vgl. Nagle und Sammon 2017, S. 3); [15] Data-Driven Business Value Matrix (vgl. Breiffuss et al. 2019, S. 11); [16] Deep Learning AI Canvas (vgl. Perez 2017); [17] Enterprise AI Canvas (vgl. Kerzel 2021, S. 5); [18] Key Activity Canvas (vgl. Hunke et al. 2020, S. 7); [19] Machine Learning Canvas (vgl. Dorard 2019); [20] Research Project Canvas (vgl. Lacruz und Oliveira Leite 2021); [21] The open data value canvas (vgl. Gao und Janssen 2022, S. 7)

Tab. 3.7: Klassifizierung der Canvas-Modelle

Die Kategorisierung der einzelnen Bestandteile nach Osterwalder (vgl. Osterwalder 2004, S. 42 ff.) ist in den Spalten der Tabelle veranschaulicht. Die Relevanz der Elemente wurde analysiert, indem die Häufigkeit der Verwendung in den Workshops und der erweiterten Literaturrecherche addiert und durch zwei dividiert wurde; diese Elemente sind zur leichteren Identifikation in Tab. 3.7 farblich grün markiert.

Neifer et al. führen neun Canvas-Modelle an, die sie anhand von 12 Elementen kategorisierten (*Geschäftsfall, Datenerfassung, Datenquelle, Datenqualität, Datenintegration, Methoden, Fähigkeiten, Software, Modellqualität, Kosten und Einnahmen, Mehrwert, Interessengruppen*) (vgl. Neifer et al. 2021, S. 5401). Das Data-Science Canvas war ihr Forschungsergebnis (vgl. Neifer et al. 2021, S. 5404). Fruhwirth et al. identifizierten neun Canvas-Modelle – fünf davon waren noch nicht in der Arbeit von Neifer enthalten (vgl. Fruhwirth et al. 2020, S. 522). Fruhwirth et al. kategorisierten die Tools anhand von fünf Elementen: *Datenquellen, Analyseansätzen, Anwenderpräferenzen, Anwendernutzen* und *Datenprodukt*, verglichen sie und entwickelten aus ihren Erkenntnissen das Data Product Canvas (vgl. Fruhwirth et al. 2020, S. 522). Durch die vertiefte Literaturrecherche in dieser Arbeit konnten sieben weitere Modelle identifiziert werden (siehe Tab. 3.7). Die Ergebnisse der Literaturrecherche halfen dabei, die Datenwertschöpfungsketten-Ontologie zu definieren. Um daraus ein eigenes Modell abzuleiten, orientiert sich diese Arbeit am Vorgehen von Osterwalder. Im Weiteren werden die Säulen analog zur BMC-Ontologie festgelegt (vgl. Osterwalder 2004, S. 42 ff.). Tabelle 3.8 zeigt eine Gegenüberstellung mit der entwickelten Datenwertschöpfungsketten-Ontologie.

BMC-Ontologie	Datenwertschöpfungsketten-Ontologie
Produkt	Datenprodukt
Schnittstelle zu Kund*innen	User Story
Verwaltung der Infrastruktur	Datenwertschöpfungsketten Infrastruktur
Finanzielle Aspekte	Bewertungsmodell

Tab. 3.8: Säulen der Datenwertschöpfungsketten-Ontologie

Die durch die Literaturrecherche entwickelte Datenwertschöpfungskette kann durch das Bewertungs- und Kennzahlensystem visualisiert und analysiert werden. Das Bewertungsmodell sollte für eine langfristige Allgemeingültigkeit anpassungsfähig bleiben – so kann auch mit der Entwicklungsgeschwindigkeit in der Wirtschaftsinformatik Schritt gehalten werden. Die Workshop-Ergebnisse aus der ursprünglich entwickelten Datenwertschöpfungsketten-Ontologie zeigten, dass die Grundstruktur in Bezug auf die verwendeten Variablen nicht optimal verteilt war. Das Ziel des innerhalb dieser Arbeit erstellten Datenwertschöpfungsketten-Canvas besteht darin, die Wertschöpfungskette von (Daten-)Produkten des BMC-Modells so genau wie möglich nachzubilden. In Tab. 3.9 wird die Erweiterung und Aufbau der Datenwertschöpfungsketten-Ontologie gezeigt.

Säule	Elemente	Beschreibung
Datenprodukt	Wertangebot	Beschreibt, welchen Wert die Datenprodukte (potenziell) für die Anwendenden haben, in Form einer relevanten Frage, die mithilfe von Daten(-Analyse) beantwortet werden kann
Anwenderschnittstelle	Kanäle	Legt fest, wie die Datenprodukte verwendet und visualisiert werden, z. B. in Form von Dashboards, Berichten usw. Die Visualisierung ist ein Unterelement der Kanäle.
	Anwenderbericht	Als ein ... [wer?] möchte ich ... [was?] wissen, um ... zu entscheiden ... [warum?]. Die Entscheidung ist ein Unterelement des Anwenderberichts (vgl. Santos 2020, S. 265)
	Kriterien für die Akzeptanz	Beschreibt die Akzeptanzkriterien der Anwendenden für die Datenprodukte
Daten-wertschöpfungskette	Schlüsselressourcen	Kombiniert Schlüsselpartner*innen und Datenquelle; Schlüsselpartner*innen ist ein Unterelement zu Schlüsselressourcen
Infrastruktur	Schlüssel-partner*innen	Beschreibt, welche internen oder externen Partner*innen an der Erstellung, Pflege oder Verbesserung der Datenprodukte beteiligt sind
	Schlüsselaktivitäten	Enthält die relevantesten Aktivitäten für die Erstellung des Datenprodukts entlang der Datenwertschöpfungskette
Bewertungsmodell	ROI _{DAQ}	ROI _{DAQ} ist der KPI für die Datenerfassung einschließlich der jeweiligen Kosten- und Ertragsaspekte und beschreibt, wie die Datenerfassung durchgeführt wird
	ROI _{DAGO}	ROI _{DAGO} ist der KPI für Data-Governance mit den entsprechenden Kosten- und Ertragsaspekten und beschreibt, wie die Data-Governance durchgeführt und bewertet wird
	ROI _{DAMA}	ROI _{DAMA} ist der KPI für das Datenmanagement einschließlich der jeweiligen Kosten- und Ertragsaspekte und beschreibt, wie das Datenmanagement durchgeführt und ausgewertet wird
	ROI _{DANA}	ROI _{DANA} ist der KPI für die Datenanalyse einschließlich der jeweiligen Kosten- und Ertragsaspekte und beschreibt, wie die Datenanalyse durchgeführt und bewertet wird
	ROI...	ROI ... (steht hier für die modulare Erweiterbarkeit des Modells)
	ROI _{DEC}	ROI _{DEC} ist der KPI für die Entscheidung unter Berücksichtigung der jeweiligen Kosten- und Ertragsaspekte

Tab. 3.9: Säulen und Elemente für die Datenwertschöpfungsketten-Ontologie

Abbildung 3.6 ist die Verbindung zwischen Säulen und Elementen zu entnehmen. Die Anordnung der Säulen in den Komponenten im Hintergrund wird durch Kästen dargestellt. Die Pfeile symbolisieren ontologische Verknüpfungen in der Datenwertschöpfungskette. Diese Grafik folgt der beschriebenen BMC-Ontologie (vgl. Osterwalder 2004, S. 104).

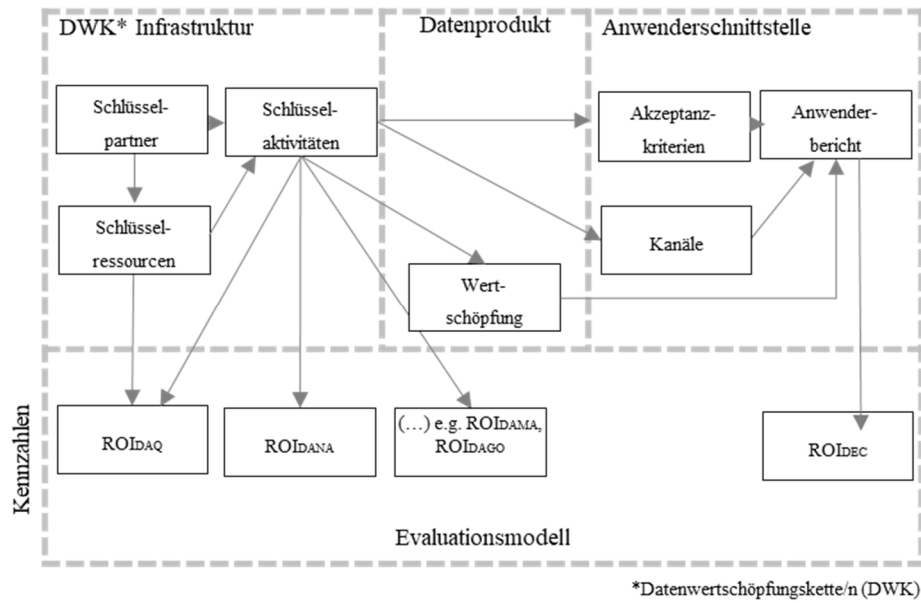


Abb. 3.6: Datenwertschöpfungsketten-Ontologie

Das Datenwertschöpfungsketten-Canvas-Modell dieser Arbeit basiert auf den Datenprodukten in der Mitte, die das Wertangebot für eine Organisation repräsentieren. Die Schlüsselpartner*innen, die Schlüsselaktivitäten sowie die Schlüsselressourcen auf der linken Seite der Abbildung bilden die Infrastruktur der Datenwertschöpfungskette analog zur BMC-Ontologie ab (vgl. Osterwalder 2004, S. 104 ff.). Der Anwenderbericht auf der rechten Seite hilft, die Schnittstellen der Anwendenden, ihre speziellen Bedürfnisse (Akzeptanzkriterien) und Kommunikationskanäle zu verstehen. Die Schlüsselressourcen und die Schlüsselpartner*innen beinhalten Datenquellen, die dazu beitragen, aus Daten einen Wert zu schaffen. Auf diese Weise ist die Datenwertschöpfungsketten-Ontologie entstanden, die in Abb. 3.6 veranschaulicht ist und in den Datenwertschöpfungsketten-Canvas (siehe Abb. 3.7) mündete; die final ausgewählten Elemente wurden grün markiert.

Schlüsselpartner*innen Welche Partner*innen wirken bei der Erarbeitung und der kontinuierlichen Bereitstellung mit? SP1 Interne und externe Partner*innen? SP2 Wie wird unterstützt? SP3 Welche Rolle hat der*die Partner*in im Data-Science-Team?	Schlüsselaktivitäten Welche Aktivitäten müssen innerhalb der Datenproduktstellung ausgeführt werden? SA1 Problemstellung SA2 Datenerhebung? SA3 Analysemethoden/Modellauswahl SA4 Datenvorbereitung SA5 Modellaufbau (Trainieren/Testen) SA6 Datenanalyse und Ergebnis (KPIs) <hr/> Schlüsselressourcen Was ist notwendig, um das Datenprodukt aufzusetzen und kontinuierlich bereitzustellen sowie zu nutzen? SR1 Erforderliche Ressourcen? SR2 Erforderliche Datenquellen? SR3 Beeinflussende Randbedingungen?	Wertschöpfung Welchen Wert hat das Datenprodukt (potentiell)? WS1 Welchen Wert hat diese Entscheidung bzw. die Verbesserung monetär? WS2 Welche Entscheidung ermöglicht das Datenprodukt? -> Verknüpfung zu ZG3 WS3 Welche nicht funktionalen Anforderungen bestehen?	Kundenbeziehung In welcher Beziehung steht der*die Data Scientist*in zum*zur Nutzer*in des Datenprodukts? KB1 Beziehung DP <> Beteiligte (Feedback Prozess)? KB2 Relevanter Prozessschritt für das DP? KB3 Akzeptanzkriterien für das Ergebnis? <hr/> Kanäle In welchem Format und welcher Frequenz wird das Datenprodukt final kommuniziert? KA1 Nutzungshäufigkeit? KA2 Gebrauchsform DP? KA3 Visualisierung? (von SA6)	Zielgruppen Wer soll das Datenprodukt im Unternehmen nutzen? ZG1 Wer wird informiert? Wem hilft das DP? ZG2 Wer entscheidet? Wer ist der*die Endnutzer*in? ZG3 Anwender*innenbericht: Als ... [wer] möchte ich .. [was] wissen, um ... zu entscheiden [warum].
Kostenstruktur Welche Kosten sind mit der Bereitstellung des Datenproduktes verbunden? KS1 Wie hoch sind die Kosten/ der Aufwand, um das Analyseergebnis des Datenproduktes zu generieren? (incl. CAPEX für Messgeräte z. B.) KS2 Wie hoch sind die Risiken des betrachteten Vorgangs?	Einkommensquellen Welcher Nutzen kann aus der Anwendung des Datenprodukts gezogen werden? Wie hoch ist dieser Wert? ES1 Welches Einkommen/ Welche Kosteneinsparungen können durch das Datenprodukt erreicht werden? ES2 Datenwert			

Abb. 3.7: Datenwertschöpfungsketten-Canvas mit priorisierten Elementen

Die verschiedenen Komponenten dieses Kapitels werden im nächsten Abschnitt ausführlicher erläutert. Dazu gehören unter anderem die Verknüpfung mit anderen Komponenten und die Kardinalität (Anzahl der Vorkommen in der Ontologie) – ähnlich wie bei der BMC-Ontologie (vgl. Osterwalder 2004, S. 47).

Datenprodukt: Eine sinnvolle Frage, die mithilfe von Daten gelöst werden kann, ist ein Datenprodukt. Das Wertangebot (Value-Proposition) eines Datenproduktes erklärt, wie und warum die Anwendenden davon profitieren sollten (siehe Tab. 3.10). Im Weiteren wird beschrieben, welche Elemente unter der Säule Datenprodukt zusammengefasst sind.

Name des Elements	Wertangebot
Definition	Das Wertangebot beschreibt, wie und warum die Anwendenden von einem Datenprodukt profitieren sollten.
Teil von	Säule: Datenprodukt
Kardinalität	1–n
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc}
Referenzen	(Vgl. Neifer et al. 2020, S. 5400; Osterwalder 2004, S. 30 f.)

Tab. 3.10: Beschreibung des Wertversprechens des Elements

Datenwertschöpfungsketten-Infrastruktur: Es wurde festgestellt, dass sich acht der 21 in der Literaturrecherche identifizierten Canvas-Modelle hauptsächlich auf das Infrastrukturmanagement konzentrieren, wobei der Schwerpunkt auf der Datenakquise, dem Datenmanagement, den Datenanalysemethoden und der Modellauswahl liegt. Tabelle 3.11 beschreibt einen der Schlüsselaspekte – die *Schlüsselressourcen*.

Name des Elements	Schlüsselressourcen
Definition	Das Element <i>Schlüsselressourcen</i> beantwortet die Frage, was für die Einrichtung und den Betrieb eines Datenprodukts erforderlich ist. Die Unterkategorien sind die benötigten Ressourcen (interne und externe Partner*innen), die Datenquellen und die Methoden. Als Minimum sollte eine potenzielle Datenquelle genannt werden.
Teil von	Datenwertschöpfungsketten-Infrastruktur
Verwandt mit	Datenquelle, Schlüsselaktivitäten, Datenanalyse(DANA)-Methode
Kardinalität	1–n
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc}
Referenzen	(vgl. Osterwalder 2004, S. 81 f.)

Tab. 3.11: Beschreibung des Elements Schlüsselressourcen

Das Element *Schlüsselpartner*innen* bestimmt, ob die Infrastruktur der Datenwertschöpfungskette interne oder externe Partner*innen erfordert (siehe Tab. 3.12). Data-Analyst*innen sowie externe Daten anbietende sind zwei Beispiele. Bestimmte Canvas-Modelle, etwa das *Key Activity Canvas* (vgl. Hunke et al. 2020, S. 7) und das *Analytics Canvas* (vgl. Kühn et al. 2018, S. 165), legen den

Schwerpunkt auf die Charakterisierung von Schlüsselaktivitäten und deren Beziehung zu den beteiligten Schlüsselpartner*innen.

Name des Elements	Schlüsselpartner*innen
Definition	Das Element <i>Schlüsselpartner*innen</i> umfasst interne und externe Partner*innen, die Art ihrer Unterstützung und die Rolle, die die Partner*innen im Data-Science-Team spielen. Bei einigen Datenprodukten ist es möglicherweise nicht erforderlich, Partner*innen einzubinden (z. B. wenn das Datenprodukt bereits existiert und automatisch berechnet werden kann).
Teil von	Datenwertschöpfungsketten-Infrastruktur
Verwandt mit	Datenerfassung (DAQ), ..., Datenanalyse (DANA)
Unterelement	Schlüsselressourcen
Kardinalität	0–n
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc}
Referenzen	(vgl. Osterwalder 2004, S. 89)

Tab. 3.12: Beschreibung der relevantesten Partner*innen des Elements

Schlüsselaktivitäten sind alle Tätigkeiten, die innerhalb der Datenwertschöpfungskette ausgeführt werden müssen, um die Ergebnisse vorzubereiten, zu analysieren oder zu visualisieren und diesen Prozess aufrechtzuerhalten (siehe Tab. 3.13). Modelle wie das Key-Activity-Canvas betonen die vielfältigen Ausprägungen der Schlüsselaktivitäten (vgl. Hunke et al. 2020, S. 7).

Name des Elements	Schlüsselaktivitäten
Definition	Beschreibt alle Schlüsselaktivitäten, die für die Erstellung und Pflege der Datenprodukte entlang der Datenwertschöpfungskette erforderlich sind
Teil von	Datenwertschöpfungsketten-Infrastruktur
Verwandt mit	ROI _{DAQ} , ROI _{DANA} Methode, Schlüsselressourcen
Unterelement	Schlüsselressourcen
Kardinalität	0–n
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc}
Referenzen	(vgl. Osterwalder 2004, S. 85)

Tab. 3.13: Beschreibung der Schlüsselaktivitäten des Elements

Anwenderschnittstelle: Neun Canvas-Modelle haben einen Fokus auf die Anwenderschnittstelle gelegt (siehe Tab. 3.14). Obwohl die von den Canvas-Modellen in diesem Bereich untersuchten Aspekte eine größere Varianz aufweisen, legen sie einen starken Fokus auf die Interaktion zwischen den Datenprodukten und den Stakeholdern sowie den internen und externen Partner*innen (z. B. *AI Project Canvas* (vgl. Zawadzki 2019) oder im *Big Data Management Canvas* (vgl. Kaufmann 2019, S. 8)). Aspekte wie die Datenquelle und die Datenerhebung sind in vielen Canvas-Modellen ebenfalls wesentlich. Die Anwenderschnittstelle teilt sich auf in den Anwenderbericht, die Kanäle und die Akzeptanzkriterien für die Anwendenden.

Name des Elements	Anwenderbericht
Definition	Der Anwenderbericht beschreibt, wie die Anwendenden mit dem Datenprodukt interagiert und über welche Kanäle es kommuniziert wird
Teil von	Anwenderschnittstelle
Verwandt mit	Kanäle, Visualisierung, Entscheidung
Unterelement	
Kardinalität	1–n
Attribute	BESCHREIBUNG für die Entscheidung, die eine Kette von Zeichen enthält {abc} BESCHREIBUNG des Anwenderberichts, die eine Kette von Zeichen {abc} enthält
Referenzen	(vgl. DasScrumTeam AG 2020)

Tab. 3.14: Beschreibung des Elements *Anwenderbericht*

Kanäle spezifizieren die Mittel, über die ein Datenprodukt mit den Anwendenden geteilt wird, einschließlich Newslettern, E-Mails, Dashboards, Berichten usw. (siehe Tab. 3.15). Data-Storytelling wird laut Data-Science Canvas (data-science-workflow-canvas) z. B. über „Online-Portale, Data Lakes, *Application Programming Interfaces* oder anwenderdefinierte Apps“ übermittelt (Gao und Janssen 2022, S. 7).

Name des Elements	Kanäle
Definition	Kanäle beschreiben, wie die Ergebnisse der Datenwertschöpfungskette an die Anwendenden verteilt werden, z. B. über Dashboards, Berichte usw.
Teil von	Anwenderschnittstelle
Verwandt mit	Anwenderbericht, Visualisierung, Entscheidung
Unterelement	Anwenderbericht
Kardinalität	0–n €
Attribute	BESCHREIBUNG der verwendeten Kanäle, die eine Kette von Zeichen enthält {abc} BESCHREIBUNG der verwendeten Visualisierung, die eine Kette von Zeichen enthält {abc}
Referenzen	(vgl. Osterwalder 2004, S. 63)

Tab. 3.15: Beschreibung des Elements *Kanal*

Die Annahme eines Datenprodukts durch Anwendende wird maßgeblich durch die Akzeptanzkriterien beeinflusst (siehe Tab. 3.16). Dies können bestimmte KPIs (vgl. Kronsbein und Mueller 2019, S. 566) oder klare Visualisierungsvorgaben sein.

Name des Elements	Akzeptanzkriterien
Definition	Beschreibt, welche Kriterien seitens der Anwendenden bestehen, um auf die präsentierten Ergebnisse der Datenprodukte zuzugreifen
Teil von	Anwenderschnittstelle
Verwandt mit	Anwenderbericht, Visualisierung, Entscheidung
Unterelement	Anwenderbericht
Kardinalität	1–n €
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc}
Referenzen	(vgl. Osterwalder 2004, S. 93)

Tab. 3.16: Beschreibung des Elements *Akzeptanzkriterien*

3.6 Kennzahlensystem

Um den Wert von Daten darzustellen, schlägt Bill Schmarzo in einem Blog-Beitrag von Dell alternativ vor, den Goodwill-Ansatz zu verfolgen (vgl. Schmarzo 2016). *Goodwill* ist ein Buchhaltungskonzept aus dem US-amerikanischen Sprachraum, mit dem Organisationen immateriellen Gütern einen Wert zuweisen können. Ein Beispiel dafür ist der Markenwert einer Organisation. Immaterielle Güter, z. B. Markenrechte einer Organisation, können auf drei verschiedene Arten bewertet werden (vgl. Nestler 2003):

- Marktwertorientiert.
- Kostenorientiert.
- Ertragsorientiert.

Das marktwertorientierte Verfahren setzt voraus, dass das zu bewertende Gut auf einem Markt gehandelt wird oder gehandelt werden kann. Anhand der Marktpreise wird der Wert ermittelt. Dieser Ansatz erscheint für den Betrieb von Onshore- und Offshore-Windparks nicht anwendbar, da die Betriebsdaten unter Betreibenden nicht gehandelt werden, weil sie sich untereinander als Wettbewerber betrachten. Das kostenorientierte Verfahren orientiert sich an den Reproduktionskosten. Damit sind die Kosten gemeint, die auftreten würden, wenn die Daten reproduziert werden sollen. Dies könnten etwa Wiederbeschaffungskosten für Sensoren sein. Das dritte Verfahren ist der ertragsorientierte Ansatz. Bei diesem Ansatz ermisst sich der Wert der Daten aus zukünftigen Erträgen, Gewinnen oder Kosteneinsparungen, die sich aus den Daten ergeben bzw. die diese ermöglichen oder steigern (vgl. Nestler 2003).

Das IT-Beratungsunternehmen Gartner schlägt verschiedene Kennzahlen und Berechnungsmethoden vor, um den Wert von Daten zu ermitteln (vgl. Laney 2018, S. 250; Rüdiger und Litzel 2015).

Diese Methoden basieren ebenfalls auf der Bewertung immaterieller Güter und sind somit ergänzend zu Schmarzos Vorschlag zu sehen.

Datenqualität ist ein bedeutender Faktor für die Datenwertschöpfung (vgl. Kordon 2020, S. 29). Der *Business-Value of Information* (BVI) bewertet die Nutzbarkeit von Daten für die eigenen Prozesse anhand von Datenqualitätskriterien. Innerhalb der Datenqualität müssen die Datenakquise, das Datenmanagement, die Datenverarbeitung und der Datentransfer bewertet werden (vgl. Klein 2009, S. 12). Es finden sich verschiedene Ansätze zur Bewertung der Datenqualität (vgl. Berti-Equille 1998, S. 250). Der BVI folgt der Definition von Wang und Strong²⁹, die in Tab. 3.17 in Form einer Übersetzung (vgl. Klein 2009, S. 22) zusammengefasst ist und um die Angabe ergänzt wurde, ob die Datenqualitätsdimensionen bereits Bestandteil des BVIs sind.

Kategorie	Dimension	Bestandteil der Analyse
Intrinsische Datenqualität	Genauigkeit Glaubhaftigkeit Objektivität Reputation	Bestandteil des BVI Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI
Kontextuelle Datenqualität	Vollständigkeit Relevanz Rechtzeitigkeit (Aktualität) Datenmenge Geschäftswert (Mehrwert)	Bestandteil oder Ergebnis des BVI Bestandteil oder Ergebnis des BVI Bestandteil oder Ergebnis des BVI Mögliche Erweiterung des BVI Bestandteil oder Ergebnis des BVI
Repräsentative Datenqualität	Interpretierbarkeit Verständlichkeit Konsistenz Prägnanz	Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI
Zugriffsqualität	Zugänglichkeit Sicherheit	Mögliche Erweiterung des BVI Mögliche Erweiterung des BVI

Tab. 3.17: Dimensionen von Datenqualität (vgl. Klein 2009, S. 22)

Innerhalb dieses Kennzahlensystems wurden analog zum BVI die Genauigkeit, die Rechtzeitigkeit (oder Aktualität) und die Vollständigkeit bewertet. Der BVI gibt, wie bereits beschrieben, den Geschäftswert wieder. Die repräsentative Datenqualität stellt eine mögliche Erweiterung für den BVI im Fall einer erweiterten Datenwertschöpfungskette dar, was für die Betrachtung allerdings ausgeklammert wird. Die Zugriffsqualität mit der Zugänglichkeit und der Sicherheit ist eine weitere Ergänzung, die für diese Arbeit ebenfalls ausgeblendet wird. Somit sind die Bestandteile des BVI definiert und entsprechen einem möglichen Gewinn eines Datenprodukts. Zur Bewertung des Gewinns wird der BVI im Kontext der Evaluation betrachtet. Die verschiedenen Variablen der

²⁹ Wang und Strong unterteilen die Datenqualität in „Intrinsic- (Believability, Accuracy, Objectivity, Reputation), Contextual- (Value-added, Relevancy, Timeliness, Completeness, Appropriate amount of data), Representational- (Interpretability, Ease of Understanding, Representational consistency, Concise representation) and Accessibility Data Quality (Accessibility and Access Security)“ (vgl. Wang und Strong 1996, S. 16).

Formel beziehen sich hierbei auf eine prozentuale Erfüllung der einzelnen Bestandteile des BVI, etwa der *Relevanz*, *Genauigkeit*, *Vollständigkeit* oder *Rechtzeitigkeit*. Sind alle Bereiche voll erfüllt, ergibt sich ein BVI nahe 1 (das entspricht einem Geschäftswert von 100 %).

Der BVI (siehe Formel 3.4) kann für einzelne oder für alle Datenprodukte berechnet werden. Er stellt folglich den Geschäftswert eines oder mehrerer Datenprodukte bezogen auf ein Entscheidungsproblem dar. Der BVI besitzt einen Fokus auf Datenqualität und kann für Evaluationen bedarfsgerecht erweitert werden.

i *Business Value of Information (BVI):*

Der BVI wurde von Laney für Gartner entwickelt (vgl. Laney 2018, S. 253 f.). Er ist je nach Einsatzbereich beliebig erweiterbar und beinhaltet Kernthemen der Datenqualität.

$$BVI = \sum_{p=1}^n (\text{Relevanz}_p) * \text{Genauigkeit} * \text{Vollständigkeit} * \text{Rechtzeitigkeit} \quad (3.4)$$

Die einzelnen Variablen liegen zwischen 0 und 1; so kann ein prozentualer Wert bestimmt werden, der einem hohen oder niedrigen Geschäftswert der Informationen entspricht. Hierbei steht p für die Geschäftsprozesse oder Funktionen und n für die Anzahl. Folgende Datenqualitätskriterien sind Bestandteile der ursprünglichen BVI-Formel. Die Relevanz (0–1) bewertet den Nützlichkeitsgrad der Daten für einen oder mehrere Geschäftsprozesse. Die Genauigkeit gibt den Prozentsatz der als korrekt erachteten Aufzeichnungen wieder. Die Vollständigkeit bewertet die Vollständigkeit des Datensatzes bezogen auf das Datenprodukt. Die Rechtzeitigkeit gibt an, wie schnell neue oder aktualisierte Daten zur Verfügung stehen. Das Ergebnis kann zusätzlich durch eine individuelle Gewichtung verfeinert werden (vgl. Laney 2018, S. 252 ff.).

Innerhalb der Betriebswirtschaftslehre existiert der *Return on Investment (RoI)* (siehe Formel 3.5) als „eine der wichtigsten Renditekennzahlen“ (Vollmuth und Zwettler 2015, S. 84 f.). Der RoI setzt den Gewinn als Nutzenfaktor mit den Kosten ins Verhältnis. Zur Bewertung des RoI können unterschiedliche Erfolgsgrößen eingesetzt werden, was einen einheitlichen Vergleich dieser Kennzahl erschweren kann (vgl. Wöltje 2021, S. 292).

i *Return on Investment (RoI):*

Beim RoI wird das mögliche Ergebnis zum eingesetzten Aufwand ins Verhältnis gesetzt.

$$RoI = \frac{\text{Gewinn}}{\text{Investiertes Kapital}} \times 100 \quad (3.5)$$

Für diese Arbeit wird die neue Kennzahl *Return on Information (ROI)* entwickelt (3.6). Für den ROI muss der BVI für verschiedene Bewertungsschritte aufgeteilt werden, um etwa seinen Anteil an der Datenanalyse und der Datenakquise zu bewerten. In dieser Arbeit liegt der Fokus auf den Bestandteilen DAQ, DAGO, DAMA, DANA sowie der Entscheidungsfindung (DEC) (siehe Formel 3.6). Damit kann der ROI für jedes Glied der Datenwertschöpfungskette berechnet werden. Die Indikatoren können als Verhältniszahl, als reale Kosten oder als Nutzwertanalyse bewertet werden. Das

Modell ist ausbaufähig und kann für andere Datenwertschöpfungsketten entlang der Datenqualitätskriterien erweitert werden.



Aufteilung des Return on Information (ROI) auf die Bestandteile der Datenwertschöpfungskette:

Für diese Arbeit wird der *ROI* zum Return on Information (*ROI*) hier beschrieben für die gesamte Datenwertschöpfungskette als ROI_{DWK} :

$$ROI_{DWK} = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^m y_i} \times \frac{m}{n} \quad (3.6)$$

In dem Fall, dass die Anzahl der Werte im Zähler oder Nenner abweicht, muss ein Korrekturfaktor (siehe Formel 3.7) eingerechnet werden:

$$\text{Korrekturfaktor} = \frac{m}{n} \quad (3.7)$$

Am Beispiel des ROI_{DEC} lautet die Formel (3.8) wie folgt:

$$ROI_{DEC} = \frac{\text{Nutzungsfrequenz} + \text{Relevanz} + \text{Rechtzeitigkeit}}{\text{Einmalige Kosten} + \text{Jährliche Kosten}} \times \frac{2}{3} \quad (3.8)$$

Durch die Skalierung ergeben sich folgende Werte (Beispiel Onshore-Skalierung, siehe Abb. 3.8):

Color	Zugänglichkeit	Kosten
3	There is full access to all data (necessary for own work)	33.000,00 €
2,5	There is mostly access to the data	17.000,00 €
2	No data	8.000,00 €
1,5	The data can be partially accessed	2.500,00 €
1	The data cannot be accessed	1.500,00 €

Abb. 3.8: Skalierung Onshore

Die Skalierung wird über Verhältniszahlen durchgeführt, sie können aus der Literatur hergeleitet werden. Kosteneinsparungen in der Betriebsführung und Instandhaltung von Onshore- und Offshore-Windparks können in die Kategorien 0–7.500 € 7.500–100.000 € > 100.000 € eingeteilt werden (vgl. Scheu et al. 2019, S. 124). Für die vorliegende Arbeit wird diese Aufteilung in ein fünfstufiges Modell (7.500 € 25.000 € 50.000 € 100.000 € 150.000 €) überführt. Für die oben gezeigte Onshore-Skalierung wurde in Rücksprache mit den Industriepartnern eine Reduktion der Kosten vorgenommen (siehe Abb. 3.9). Die detaillierte Skalierung findet sich im Anhang E.

Farbe	Relevanz	Kosten	Farbe	Relevanz	Kosten
3	Sehr wichtig	33.000,00 €	3	Sehr wichtig	150.000,00 €
2,5	Wichtig	17.000,00 €	2,5	Wichtig	100.000,00 €
2	Weniger wichtig	8.000,00 €	2	Weniger wichtig	50.000,00 €
1,5	Kaum wichtig	2.500,00 €	1,5	Kaum wichtig	25.000,00 €
1	Unwichtig	1.500,00 €	1	Unwichtig	7.500,00 €

Abb. 3.9: Onshore- im Vergleich zur Offshore-Skalierung am Beispiel der Relevanz

Die folgende Tabelle 3.18 zeigt eine Übersicht über die Variablen für die Bewertung des BVI.

Variable	Beschreibung	Beispiel
BVI_{DWK}	BVI-Anteil der Datenwertschöpfungskette	DAQ, DAGO, DAMA, DANA oder DEC
n	Anzahl der Werte im Zähler	$BVI_{DEC} = \frac{\text{Nutzungsfrequenz} + \text{Relevanz} + \text{Rechtzeitigkeit}}{\text{Einmalige Kosten} + \text{Jährliche Kosten}} \times \frac{2}{3} \quad (3.9)$
m	Anzahl der Werte im Nenner	
$\sum_{i=1}^n x_i$	Summe der Werte im Zähler	
$\sum_{i=1}^m y_i$	Summe der Werte im Nenner	

Tab. 3.18: Genutzte Variablen für die Bewertung der BVI-Bestandteile am Beispiel des BVIDEC (siehe Formel 3.9)

Während die ROIs dabei helfen, die Bereiche der Datenwertschöpfungskette mit der höchsten Rendite zu identifizieren, stellt das Ambitionslevel eine weitere Kennzahl dar, über die ein Datenprodukt bewertet werden kann. Jede Entscheidung bzw. jedes Datenprodukt ist einer Kategorie und somit einem Ambitionslevel zugeordnet; damit kann auch ein *Return on Ambition (RoA)* pro Datenprodukt abgeleitet werden.

Um den RoA für Datenprodukte zu bewerten, werden die verschiedenen ROI (ROI_{DAQ} , ROI_{DANA} und ROI_{DEC}) und das Ambitionslevel addiert. Daraus ergibt sich eine Verhältniszahl, die eine klare Priorisierung aller Datenprodukte ermöglicht. Das Ambitionslevel als unabhängige Variable, die die Organisationsziele darstellt, wird addiert, um eine Übergewichtung der eingeschätzten Relevanz der Datenprodukte aus den Geschäftsbereichen zu vermeiden.

Return on Ambition (RoA):

i Die ursprüngliche Idee hinter dem RoA (siehe Formel 3.10) bezieht sich auf ein Maß für die persönliche Weiterentwicklung (vgl. Chen Nielsen und Tillisch 2021, S. 27 ff.)³⁰.

$$RoA = Achievement (A) + Growth (G) + WellBeing (WB) \quad (3.10)$$

Ausgehend von diesem Grundgedanken wurde eine eigene Formel (3.11) entwickelt:

$$ROA_{DWK} = ROI_{DAQ} + ROI_{DANA} + ROI_{DEC} + Ambitionslevel (AL) \quad (3.11)$$

Um die Datenwertschöpfungskette zu bewerten und Optimierungsmaßnahmen zu identifizieren, wird das beschriebene Kennzahlensystem im Weiteren zusammengefasst (siehe Tab. 3.19).

Variable	Ablauf (Formel)
BVI _{DWK}	$BVI_{DWK} = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^m y_i} \times \frac{m}{n}$
Korrekturfaktor	$Korrekturfaktor = \frac{m}{n}$
Datenakquise (DAQ)	$BVI_{DAQ} = \frac{Vollständigkeit + Genauigkeit}{Einmalige Kosten + Jährliche Kosten}$
Data-Governance	$BVI_{DAGO} = \frac{Integrität + Konsistenz}{Einmalige Kosten + Jährliche Kosten}$
Datenmanagement	$BVI_{DAMA} = \frac{Zugänglichkeit+Glaubwürdigkeit+Interpretierbarkeit}{Einmalige Kosten+Jährliche Kosten} \times \frac{2}{3}$
Datenanalysemethode (DANA)	$BVI_{DANA} = \frac{Wertschöpfung der Datenanalyse}{Implementierungsaufwand}$
Entscheidung (DEC)	$BVI_{DEC} = \frac{Nutzungsfrequenz + Relevanz + Rechtzeitigkeit}{Einmalige Kosten + Jährliche Kosten} \times \frac{2}{3}$
Return on Ambition (RoA)	$RoA_{DWK} = ROI_{DAQ} + ROI_{DANA} + ROI_{DAMA} + ROI_{DANA} + ROI_{DEC} + AL$

Tab. 3.19: Kennzahlensystem für das Evaluationsmodell

Nach der Bewertung der Kennzahlen können die Ergebnisse visualisiert werden, um von der lösungsbeschreibenden Sprache der Data-Science eine Brücke zu schlagen zur problembeschreibenden Sprache der Anwendenden innerhalb der Anwendungsdomäne (vgl. Kordon 2020, S. 46).

Das Kennzahlensystem wurde durch qualitative Literaturrecherchen und Interviews mit Expert*innen geschärft. Das Modell sollte grundlegend und weitgehend anpassbar sein, um übertragbar zu sein. Indikatoren weisen bei der Modellevaluation Optimierungspotenziale auf. Das Modell beginnt bei der Datenakquise mit dem ROI_{DAQ} (siehe Tab. 3.20).

³⁰ Chen Nielsen und Tillisch arbeiten mit diesem Begriff als Denkmuster für das Messen persönlicher Ambitionen im Bereich der Selbstoptimierung (vgl. Chen Nielsen und Tillisch 2021). Da die Originalkennzahl keine Übertragbarkeit auf das vorliegende Evaluationsziel ermöglicht, soll hier lediglich der Grundgedanke des RoA entliehen werden.

Name des Elements	ROI _{DAQ} Return on Information Datenakquise
Definition	Beschreibt die Datenerfassung in einfacher Sprache und bewertet die Indikatoren, wie in der Erläuterung des Bewertungsmodells beschrieben
Teil von	Finanzielle Aspekte
Verwandt mit	ROI
Unterelement	
Kardinalität	0–n €
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc} Wert für Vollständigkeit (0–n) € Wert für Genauigkeit (0–n) € Wert für einmalige Kosten (0–n) € Wert für jährliche Kosten (0–n) €
Referenzen	Eigene Entwicklung

Tab. 3.20: Beschreibung des Elements ROI_{DAQ}

Der ROI_{DAGO} (siehe Tab. 3.21) umfasst die Praktiken und Rollen der Datenqualitätskontrolle einer Organisation (vgl. Fryman et al. 2016, S. 203 f.). Im Big Data Management Canvas (vgl. Kaufmann 2019, S. 8) wird dieser Ansatz als *Data-Knowledge-Management* oder *Data-Knowledge-Engineering* bezeichnet.

Name des Elements	ROI _{DAGO} Return on Information Datenverwaltung
Definition	Beschreibt die Data-Governance in einfacher Sprache und bewertet die Indikatoren, wie in der Erläuterung des Bewertungsmodells beschrieben
Teil von	Finanzielle Aspekte
Verwandt mit	ROI
Unterelement	
Kardinalität	0–n €
Attribute	TBD BESCHREIBUNG, die eine Kette von Zeichen enthält {abc} Wert für Integrität (0–n) € Wert für Konsistenz (0–n) € Wert für einmalige Kosten (0–n) € Wert für jährliche Kosten (0–n) €
Referenzen	Eigene Entwicklung

Tab. 3.21: Beschreibung des Elements ROI_{DAGO}

Die Bewertung des ROI_{DAMA}, eines entscheidenden Glieds der Datenwertschöpfungskette, ist die nächste Phase (siehe Tab. 3.22). Bei bestimmten Canvas-Modellen greifen Datenintegration³¹ als

³¹ Verknüpfung vieler Datenquellen zur Verbesserung der Ergebnisse.

besonderer Teil der Datensammlung und das Datenmanagements ineinander (vgl. Neifer et al. 2021, S. 5403).

Name des Elements	ROI _{DAMA} Return on Information Datenmanagement
Definition	Beschreibt das Datenmanagement in einfacher Sprache und bewertet die Indikatoren, wie in der Erläuterung des Bewertungsmodells beschrieben
Teil von	Finanzielle Aspekte
Verwandt mit	ROI
Unterelement	
Kardinalität	0–n €
Attribute	TBD BESCHREIBUNG, die eine Kette von Zeichen enthält {abc} Wert für Barrierefreiheit (0–n) € Wert für Glaubwürdigkeit (0–n) € Wert für Interpretierbarkeit (0–n) € Wert für einen Korrekturfaktor Wert für einmalige Kosten (0–n) € Wert für jährliche Kosten (0–n) €
Referenzen	Eigene Entwicklung

Tab. 3.22: Beschreibung des Elements ROI_{DAMA}

Das *AI Canvas* (vgl. Agrawal et al. 2018), das *Deep Learning AI Canvas* (vgl. Perez 2017) und das *Machine Learning Canvas* (vgl. Dorard 2019) setzen einen sehr starken Fokus auf die Datenanalyse (vgl. Neifer et al. 2021, S. 5401). In dem in dieser Arbeit entwickelten Modell wird die Datenanalyse vom ROI_{DANA} (siehe Tab. 3.23) repräsentiert.

Name des Elements	ROI _{DANA} Return on Information Datenanalyse
Definition	Beschreibt die Datenanalyse in einfacher Sprache und bewertet die Indikatoren, wie in der Erläuterung des Bewertungsmodells beschrieben
Teil von	Finanzielle Aspekte
Verwandt mit	ROI
Unterelement	
Kardinalität	0–n €
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc} Wert für Wertschöpfung (0–n) € Wert für Implementierungsaufwand (0–n) €
Referenzen	Eigene Entwicklung

Tab. 3.23: Beschreibung des Elements ROI_{DANA}

Der ROI_{DEC} zeigt den zugrunde liegenden Entscheidungswert eines Datenprodukts (siehe Tab. 3.24). Im *Data Innovation Board* (vgl. Kronsbein und Mueller 2019, S. 565) wird die Entscheidung auf die Bedürfnisse der Anwendenden ausgeweitet und ihre Relevanz an der Nutzungshäufigkeit bemessen.

Name des Elements	ROI_{DEC} Return on Information – Entscheidung
Definition	Beschreibt die Entscheidung in einfacher Sprache und bewertet die Indikatoren, wie in der Erläuterung des Bewertungsmodells beschrieben
Unterelement	Finanzielle Aspekte
Verwandt mit	ROI
Unterelement	
Kardinalität	0–n €
Attribute	BESCHREIBUNG, die eine Kette von Zeichen enthält {abc} Wert für Häufigkeit der Nutzung (0–n) € Wert für Relevanz (0–n) € Wert für Aktualität (0–n) € Wert für einen Korrekturfaktor Wert für einmalige Kosten (0–n) € Wert für jährliche Kosten (0–n) €
Referenzen	Eigene Entwicklung

Tab. 3.24: Beschreibung des Elements ROI_{DEC}

Da einige KPIs möglicherweise skaliert werden müssen, ist ein Korrekturfaktor zu verwenden, wenn die Anzahl der Variablen im Zähler und Nenner ungleich ist.

3.7 Visualisierung der Datenwertschöpfungskette durch Software-Prototyp

Einen Ansatz zur Untersuchung und Darstellung des Datenflusses stellt das Datenfluss- oder Data-Flow-Diagramm dar, allerdings kann es für die fehlende formelle Sprache der semantischen Spezifikation kritisiert werden (vgl. Jilani et al. 2008, S. 153). So können durch menschliche Fehler leicht Inkonsistenzen in ein Data-Flow-Diagramm eingearbeitet werden (vgl. Ibrahim und Yen Yen 2011, S. 60). Diese fehlende Einheitlichkeit der Form kann in Gesprächen mit Personen aus verschiedenen Organisationsbereichen schnell zu Missverständnissen führen. Ein Datenfluss kann z. B. auch in einem Unified-Modeling-Language-Aktivitätsdiagramm dargestellt werden. So lassen sich etwa Entscheidungsprozesse innerhalb einer Organisation abbilden. Gleichwohl kann aus diesen Prozessen nicht abgeleitet werden, welchen Anteil Daten am Wertschöpfungsprozess haben oder welchen Wert sie aufweisen. Gleichzeitig kann es bei Anwendenden zur Verwechslung z. B. von Aktivitätsdiagrammen mit der Business Process Modeling Notation kommen, die eine ähnliche Semantik nutzt (vgl. Venera Geambasu 2012, S. 645). Um eine gemeinsame Sprache mit verschiedenen Projektbeteiligten zu finden, scheint daher eine reine statische Prozessdarstellung nicht auszureichen. Der

Datenfluss und seine Verwendung innerhalb der Organisation müssen vielmehr als organischer Ablauf verstanden werden, in dem Daten als relevante Ressource durch die Organisationsstruktur fließen und Entscheidungen unterstützen. Sankey-Diagramme sind eine etablierte Methode, um effiziente Ressourcennutzung verständlich abzubilden (vgl. Schmidt 2008, S. 83). Bisher wurde diese Darstellungsform für Daten allerdings noch nicht innerhalb der Domäne Offshore-Wind oder zur Visualisierung von Datenflüssen genutzt. Dieses Diagramm bietet die Möglichkeit, Eingangsdaten, Datenflüsse, Methoden zur Datenauswertung und Ausgabewerte gemeinsam mit resultierenden Entscheidungen darzustellen, und bildet so den Kern der Visualisierung der Datenwertschöpfungskette.

Das Sankey-Diagramm ist ein Visualisierungswerkzeug zur Darstellung von Energie-, Ressourcen- oder Kostenflüssen. Hauptbestandteile des Sankey-Diagramms sind Flüsse (oder Datenströme), deren Dicke die Menge oder den Wert des Flusses anzeigt, sowie Knoten, an denen die verschiedenen Flüsse zusammenfließen bzw. sich trennen (vgl. Keimer und Egle 2020, S. 174; Tomanek und Schröder 2018, S. 24). Bei Google Analytics werden sie als Visualisierung des Flusses von Besuchenden von Webseiten genutzt (vgl. Bitkom 2014, S. 104; Brath und Jonker 2015, S. 41 ff.). Sankey-Diagramme können mit zusätzlichen Grafiken angereichert werden, um den Erkenntnisgewinn zu erhöhen (vgl. Brath und Jonker 2015, S. 43). Eine weitere Studie vergleicht die Darstellung von Sankey- mit Node-Link-Diagrammen innerhalb von Cybersicherheitsprojekten (vgl. Blinder et al. 2019, S. 502). In dieser Studie mussten Studierende und Datenbankadministrator*innen Fragen anhand beider Diagrammtypen beantworten. Die Studie zeigte eine geringfügig schnellere Beantwortung der Fragen mithilfe des Node-Link-Diagramms, indes hatten die Anwendenden eine höhere Präferenz für die Darstellung der Daten in Form des Sankey-Diagramms (vgl. Blinder et al. 2019, S. 505 ff.). Kritisch betrachtet werden muss bei dieser Studie, dass einige Studierende oder Datenbankadministrator*innen mit der Darstellung des Node-Link-Diagramms vermutlich vertraut waren; so ist eine allgemeine Aussagekraft zumindest zweifelhaft (vgl. Blinder et al. 2019, S. 514).

Visualisierungsmethoden wie Sankey-Diagramme bilden eine Standardmethode in Forschung und Ingenieurwissenschaften, um effiziente Ressourcennutzung kompakt und verständlich zu veranschaulichen (vgl. Schmidt 2008, S. 83). Sankey-Diagramme zeichnen sich insbesondere durch die leichte Verständlichkeit der visuellen Darstellung von Daten aus, die es Betrachtenden ermöglicht, auch komplexe Zusammenhänge zu begreifen (vgl. Möller und Hedemann 2018, S. 269). So ist eine „Zeichnung besser als eine lange Rede“ (Lachal 2019, S. 59). Aus diesem Grund werden Sankey-Diagramme in der Wirtschaft auch für Wertschöpfungsketten genutzt (vgl. Keimer und Egle 2020, S. 174). Um das Sankey-Diagramm optimal einsetzen zu können, sollten die Datenströme als Summe stets 100 % ergeben (vgl. Keimer und Egle 2020, S. 174).

Besonders häufig werden Sankey-Diagramme auch dazu verwendet, Flüsse wie den Material- oder Energiefluss abzubilden (vgl. Chagnes et al. 2016, S. 31 ff.; Li et al. 2017, S. 479). Ein Ziel ist dabei, die Ressourceneffizienz zu erhöhen, indem Einsparungspotenziale schneller sichtbar werden

(vgl. Hernandez et al. 2017, S. 2378). Das Sankey-Diagramm ist zum einen in der Lage, Verluste auszuweisen (vgl. Lachal 2019, S. 62). Zum anderen können in ihm Kreisläufe und Rückflüsse dargestellt werden.

Für die Darstellung eines traditionellen Sankey-Diagramms ist eine fünfstufige Prozedur notwendig (vgl. Hernandez et al. 2017, S. 2378). Zunächst muss der Arbeitsprozess verstanden werden, gefolgt von der Umrechnung der Energie- und Stoffströme zur Vereinheitlichung von Größen- und Zeitskalen, um die Visualisierung des Sankey-Diagramms durchführen zu können (vgl. Hernandez et al. 2017, S. 2378). Da das Sankey-Diagramm eine Gewichtung der verschiedenen Zweige des Diagramms ermöglicht, muss eine Bewertung der Datenanalyse stattfinden. Hierbei können verschiedene Ansätze der erwähnten Bewertungsmethoden kombiniert werden oder einzeln Verwendung finden. Die Methode hängt stark von den in der Organisation vorhandenen Daten und deren möglicher Auswertung ab. Durch diese Bewertung von Daten als Ressource kann eine Analyse der Effizienz der Datennutzung für Entscheidungen durchgeführt und ein gewichteter Datenfluss abgebildet werden.

Es existieren zahlreiche Werkzeuge, um Sankey-Diagramme zu veranschaulichen, etwa *e!Sankey Calc* zur Modellierung von Material- bzw. Energieflüssen (vgl. Möller und Hedemann 2018, S. 273). Eine weitere Möglichkeit der Darstellung bildet die Visualisierung durch Microsofts *Power BI* (vgl. Aspin 2016, S. 399 f.) oder Python.

Sankey-Diagramme können in Verbindung mit einem Sunburst-Diagramm etwa zum Vergleich von Energieflüssen mit dem täglichen Energiebedarf genutzt werden (vgl. Azaza et al. 2019, S. 3212). Der Zweck des im Weiteren beschriebenen Software-Prototyps besteht darin, die in den Evaluationen mit den Anwendenden aufgenommenen Informationen über die Datenwertschöpfungskette auszuwerten und zu analysieren. So kann visualisiert werden, wie die Datenwertschöpfungskette funktioniert und welche Elemente ggf. verbessert werden müssen. Der Aufbau des Software-Prototyps ist in Abb. 3.10 ersichtlich; er wurde mit verschiedenen Open-Source-Paketen wie *Plotly*³² oder *Pandas* umgesetzt und über ein Jupyter-Notebook visualisiert.³³

³² Quelle: (Plotly Technologies Inc. 2015).

³³ Eine ausführbare Version des Prototypen kann per E-Mail bei dirk.bendlin@gmx.de angefragt werden.

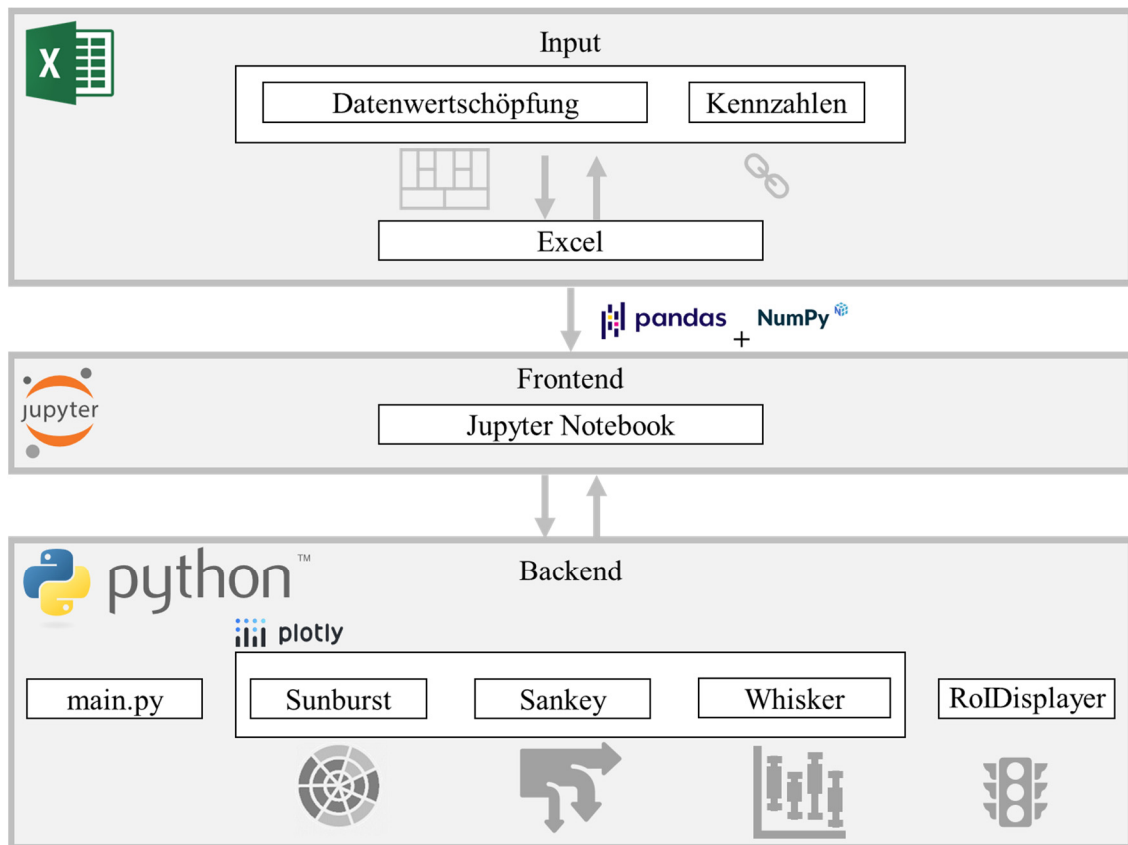


Abb. 3.10: Schematische Darstellung des Software-Prototyps³⁴

Die fehlende Unterstützung durch die Leitung einer Organisation kann ein Grund dafür sein, dass Data-Science nicht eingesetzt wird (vgl. Kordon 2020, S. 62). Um dieser Herausforderung zu begegnen, ist es erforderlich, die Ziele und Ambitionen einer Organisation innerhalb der Evaluation abzubilden und mit den Analysezielen der Datenprodukte zu verknüpfen. Die von Ramboll entwickelte *Sustainability Toolbox* (vgl. Bjerregaard Orby 2020) hat das Ziel, das Ambitionslevel in Bezug auf Nachhaltigkeitsmaßnahmen in Organisationen zu visualisieren. Der schematische Prozess wird im Weiteren erläutert. Im ersten Schritt wird ein Projekt angelegt, im zweiten Schritt wird mit den Kunden und Kundinnen die Kategorisierung besprochen und priorisiert. Jede für Nachhaltigkeit relevante Hauptkategorie setzt sich aus mehreren Unterkategorien zusammen (vgl. WorldGBC 2019). Zu jeder dieser Kategorien wurde ein Ambitionslevel von 0–5 definiert, wobei 5 das höchste Ambitionslevel abbildet. Der Vorteil dieser Methode besteht in der schnellen Durchführbarkeit mit verschiedenen Ansprechpartner*innen sowie Anwendenden in Organisationen. Einen Nachteil verkörpert indes die Ungenauigkeit der Angaben, da die Ambitionslevel pro Haupt- bzw. Unterkategorie je nach Rolle und Funktion der Befragten innerhalb der Organisation abweichen können. Um diesen

³⁴ Quelle Logos: Python (<https://www.python.org/community/logos/>), NumPy (NumPy.org), Excel (Datei: Microsoft Excel Logo (https://de.wikipedia.org/wiki/Datei:Microsoft_Excel_Logo.svg), Plotly (https://plotly.com/all_static/images/graphing_library_dark.svg), jupyter (Group.svg (jupyter.org))

Herausforderungen zu begegnen, wurden Definitionen der verschiedenen Ambitionslevel innerhalb der Sustainability Toolbox eingefügt. Durch diese Beispiele in Textform fällt es den Teilnehmenden einer Befragung leichter, Ambitionslevel auszuwählen. Im Bereich eines Sunburst-Diagramms können folgende Faktoren die Anwenderfreundlichkeit deutlich erhöhen (vgl. Keimer und Egle 2020, S. 175 f.): individualisierte Anpassungen der Dimensionsreihenfolge, informationsgerechte farbliche Abgrenzungen, Zusatzinformationen durch Mouse-over, Hinein- und Herauszoomen durch die verschiedenen Elemente.

Sunburst: Um den gewünschten Zustand für die Entscheidungsprozesse zu bewerten, müssen die Ambitionslevel in den verschiedenen Bereichen des Asset-Managements der Betreiberfirmen untersucht werden. Die Grundlage für diese Bewertung ist die EN 15341 *Maintenance Key Performance Indicators* (vgl. CEN 2019). Diese Norm definiert verschiedene Kategorien/Felder innerhalb des Asset-Managements mit entsprechenden KPIs, die als Grundlage für die Bewertung dienen sollen.

Im Ergebnis der Befragung wird ein gewichtetes Sunburst-Diagramm erstellt, das die Ambitionslevel pro Haupt- und Unterkategorie wiedergibt. Das Ambitionslevel stellt einen projizierten, potenziellen, erweiterten Return dar, den eine Organisation (oder eine Organisationseinheit) für eine Kategorie erreichen möchte.

Der Sunburst-Reiter der Datenprodukttable enthält die Daten für die verschiedenen EN-Kategorien, ihre Ambitionslevel und Beschreibungen für jede Kategorie sowohl in deutscher als auch in englischer Sprache.

Der Wert für jede Unterkategorie kann durch Ausfüllen der Zeile *Wert in %* definiert werden. Die verschiedenen Kategorien werden mit einer Skala von 0–100 % Ambition in fünf 20-%-Schritten von Anwendenden bewertet, wie vorab beschrieben. Anhand der Werte werden die Farben im Sunburst-Diagramm festgelegt (bzw. die Deckkraft wird bestimmt).

Sankey: Zu Beginn wird die ausgefüllte Exceltabelle von Pandas eingelesen und, wo nötig, transformiert (im Sheet Selector). Die Daten für den ROI werden gesondert gespeichert. Im nächsten Schritt werden Tabellenabschnitte mit multivariablen Auswahlmöglichkeiten (wie bei der Datenquelle und der Methode) transformiert. So ersetzt der Code die mit x markierten Spalten durch *True* und freie Felder durch *False* (siehe Tab. 3.25). Die eingelesene Tabelle ist weitaus umfassender als die Darstellung und beinhaltet ebenfalls die vorab beschriebenen Kategorien für das spätere Filtern und Zuweisen der Datenprodukte.

Data Acquisition												Method														
Data Basis / Source												What data processing is involved to derive the KPI?														
Metoclean	Protocol	Sensors (SHM/SMS/SCADA)	Tables	Audio & Video / Image material	Dashboard	SAP (Enterprise Resource Planning (ERP))	Rotorsoft (PPS)	Web & Social	Log files	CRM	Text	Others	Statistics from TS	Averaging	Filters	Trend analysis	Comparison to reference	Difference Δ	Percentage share %	Distribution fit	Machine Learning	Regression	Clustering	Blackbox	Mannell	Others
FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	

Tab. 3.25: Beispielhafter Tabellenabschnitt mit multivariablen Auswahlmöglichkeiten

Enthält eine Zeile mehrere Optionen, wird sie in mehrere Reihen aufgeteilt, sodass jede Zeile nur einen eindeutigen Fluss beinhaltet. Im Anschluss werden Listen erzeugt, in denen jedes Element einen Wert und eine Farbe aufweist. In einer *for*-Schleife werden alle einzelnen Reihen und deren Spalten in gewünschter Reihenfolge aufgesplittet. Daraus werden Paare kreiert, die aus einer Quelle und einem Ziel bestehen. Den Paaren werden eine Gewichtung entsprechend dem ROI-Wert und eine Farbe zugeordnet. Die geeigneten ROI-Spalten werden durch ein Wörterbuch (Dictionary) ermittelt, das dem Glied der Datenwertschöpfungskette den passenden ROI-Spaltnamen zuweist.

Unter Verwendung des Wörterbuchs wird ein Plotly-Sankey-Diagramm erstellt. Die Figur wird dann mithilfe des Dash-Python-Package im Webformat angezeigt. Im Ergebnis entsteht eine Kombination aus einem Sunburst- und einem Sankey-Diagramm. Während das Sunburst-Diagramm die Ambitionslevel für die vorgegebenen Kategorien zeigt, kann die Datenwertschöpfungskette im Sankey-Diagramm betrachtet werden.

ROI-Displayer: Die Datenwertschöpfungskette wird für die Darstellung durch ein Bewertungsmodell und Kennzahlensystem ergänzt. Diese Variablen ermöglichen es, die Wertschöpfung und die damit verbundenen Aufwände der Datenprodukte zu bewerten. Um das Kennzahlensystem als Repräsentation der Datenwertschöpfungskette zu visualisieren, bieten sich die vorab beschriebenen Sankey-Diagramme an. Für die Umsetzung der Kennzahlen in ein Sankey-Diagramm müssen Bestandteile wie etwa die Datenakquise (DAQ), die Datenanalyse (DANA) sowie die Entscheidung (DEC) transformiert werden (siehe Abb. 3.11).

$$\begin{array}{ccc}
 ROI_{DAQ} = \frac{BVI_{DAQ}}{Aufwand_{DAQ}} & \dots & ROI_{DANA} = \frac{BVI_{DANA}}{Aufwand_{DANA}} & \dots & ROI_{DEC} = \frac{BVI_{DEC}}{Aufwand_{DEC}} \\
 \downarrow & & \downarrow & & \downarrow \\
 TeilRoI_{DAQ} = Gesamt_{ROI} * ROI_{DAQ} \dots & & TeilRoI_{DANA} = TeilRoI_{DAQ} * ROI_{DANA} & & TeilRoI_{DEC} = TeilRoI_{DANA} * ROI_{DEC}
 \end{array}$$

Abb. 3.11: Kennzahlentransformation für die Sankey-Visualisierung

Durch die Transformierung (siehe Abb. 3.11) ergeben sich Werte, die die Visualisierung über ein Sankey-Diagramm ermöglichen. Die Priorisierung der Datenprodukte durch RoA und ROI ermöglichte es, im nächsten Schritt eine weitere optionale Schärfung der Datenprodukte durch eine Erhöhung des Detaillierungsgrades vorzunehmen. Durch diese Bewertungen kann eine erste Visualisierung der Ergebnisse durchgeführt werden. Ein schematischer Entwurf für eine mögliche Visualisierung findet sich in Abb. 3.12 mit einem Sunburst-Diagramm und einem Whisker-Diagramm, um bei Bedarf zusätzliche Indikatoren in die Visualisierung einzufügen.

Jeder der einzelnen Bestandteile des Kennzahlensystems wird mithilfe der Skalen von den Anwendenden bewertet. Der ROI_{DANA} beurteilt die Wertschöpfung und den Implementierungsaufwand der Datenanalyse anhand einer Nutzwertanalyse. Neben der Priorisierung der Datenprodukte wird die Nutzwertanalyse hier als Alternative zur Skalierung verwendet, um den ROI_{DANA} im Sankey-Diagramm darzustellen.

Whisker: Ein Whisker-Diagramm, auch bekannt als Candlestick-Diagramm, wird erstellt, um die Verteilung der einzelnen ROI zu veranschaulichen. Auf diese Weise lässt sich die Charakteristik der Datenwertschöpfungskette analysieren. Durch zukünftige Forschung könnte dadurch ein Branchendurchschnitt ermittelt werden, um Organisationen einen Vergleich zu ermöglichen. Im Folgenden ist ein Beispiel für ein solches Schaubild oder Diagramm angeführt; die Erweiterbarkeit ist durch „...“ impliziert (siehe Abb. 3.12).

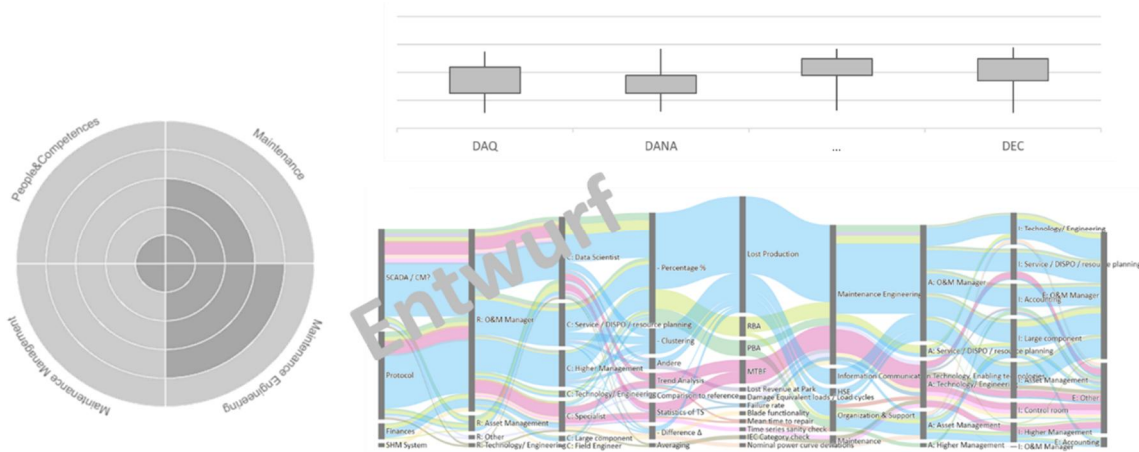


Abb. 3.12: Entwurf der Datenwertschöpfungsketten-Visualisierung inklusive Whisker-Diagramm

Das Diagramm wird in der Hauptübersicht der Datenwertschöpfungskette angezeigt. Um das Diagramm zu erstellen, müssen die Gesamtwerte für die jeweiligen ROIs (ROI_{DAQ} , ROI_{DANA} , ROI_{DEC} etc.) aus der Excel-Tabelle eingelesen und vom Prototyp analysiert werden. Mit diesen Informationen wird eine Darstellung des Plots in Dash gezeichnet.

Anwenderschnittstelle: Visuelle Anwenderschnittstellen wurden bereits wissenschaftlich untersucht. So existiert etwa das *Visual Information Seeking Mantra*, das sich als „Overview first, zoom and

filter, then details on demand“ zusammenfassen lässt (Shneiderman 1996, S. 337). Mit diesem Mantra liefert er einen ersten Hinweis auf die zentralen Bestandteile einer erfolgreichen Visualisierung. In Sankey-Diagrammen ist das größte Problem die Darstellung zu vieler Datenreihen; dadurch wird das Diagramm unübersichtlich und schwer lesbar (vgl. Schwabish 2021, S. 128). Um die Anwenderfreundlichkeit von Sankey-Diagrammen zu erhöhen, können drei Hauptkomponenten nach der ISO-Norm 9241 *Ergonomie der Mensch-System-Interaktion* herangezogen werden: Effektivität, Effizienz und Zufriedenheit (vgl. Keimer und Egle 2020, S. 172). Zur Messung und Verbesserung dieser Punkte verwendeten Keimer und Egle Eye-Tracking, um daraus Gestaltungsregeln abzuleiten (vgl. Keimer und Egle 2020, S. 173). Ein Nachteil besteht darin, dass Sankey-Diagramme entweder zu stark vereinfachen oder zu komplex werden und somit häufig ohne erläuternden Text nicht mehr lesbar sind. Alternativ schlägt Schwabish vor, verschiedene Sankey-Ansichten zu verwenden (vgl. Schwabish 2021, S. 129). Anwendende sollten bei der Nutzung des Diagramms durch Auswahlmöglichkeiten und farbliche Hervorhebungen unterstützt werden (vgl. Keimer und Egle 2020, S. 175). Eine weitere Verbesserung bieten dynamische Diagramme und Dashboards, die je nach Fragestellungen Informationen ein- oder ausblenden können. Als besonders hilfreich stellten sich laut Keimer und Egle folgende Zusatzfunktionen heraus: „Verschiebung der Dimensionen in Kombination mit der Hervorhebung von einem oder mehreren Verbindungsströmen“ sowie das An- und Abwählen verschiedener Filter und eine Anpassung der Farbgebung bezogen auf die informationsrelevante Visualisierung (Keimer und Egle 2020, S. 175).

Um die oben dargestellten Anforderungen aufzunehmen und Anwendenden durch die finale Visualisierung zu ermöglichen, vom Allgemeinen auf das Spezielle zu schließen, wurden den Diagrammen daher Filteroptionen und weitere Layout-Parameter (etwa zum Farbwechsel) hinzugefügt. Im ersten Schritt wird eine Gesamtübersicht über die verschiedenen Datenprodukte und die Datenwertschöpfungskette gegeben. Hier kann nach den Industriepartnern gefiltert werden. Weitere Filtermöglichkeiten erlauben es, nach den Datenquellen (Datenakquise), den KPIs, dem Identifier, der Methode oder den Anwendenden zu filtern. Zusätzlich besteht die Möglichkeit, die Einfärbung der Datenwertschöpfungskette anhand dieser Filter zu verändern. Durch die Filter ist bereits eine detailliertere Analyse möglich; so können einzelne Datenquellen betrachtet oder Methoden und ihr Beitrag für die Datenwertschöpfungskette bewertet werden. Im nächsten Schritt lassen sich die einzelnen Bestandteile der Datenwertschöpfungskette auf Datenproduktebene analysieren. Durch die Skalierung wird eine Bewertung der Schwachstellen innerhalb der Datenwertschöpfungskette ermöglicht. Die Beschreibung der Einheiten erlaubt eine leichtere Bewertung durch Anwendende. Die Zuordnung zu Ampelfarben dient einer schnelleren Identifizierung von Schwachstellen innerhalb der Datenwertschöpfungskette (siehe exemplarisch Abb. 3.13).

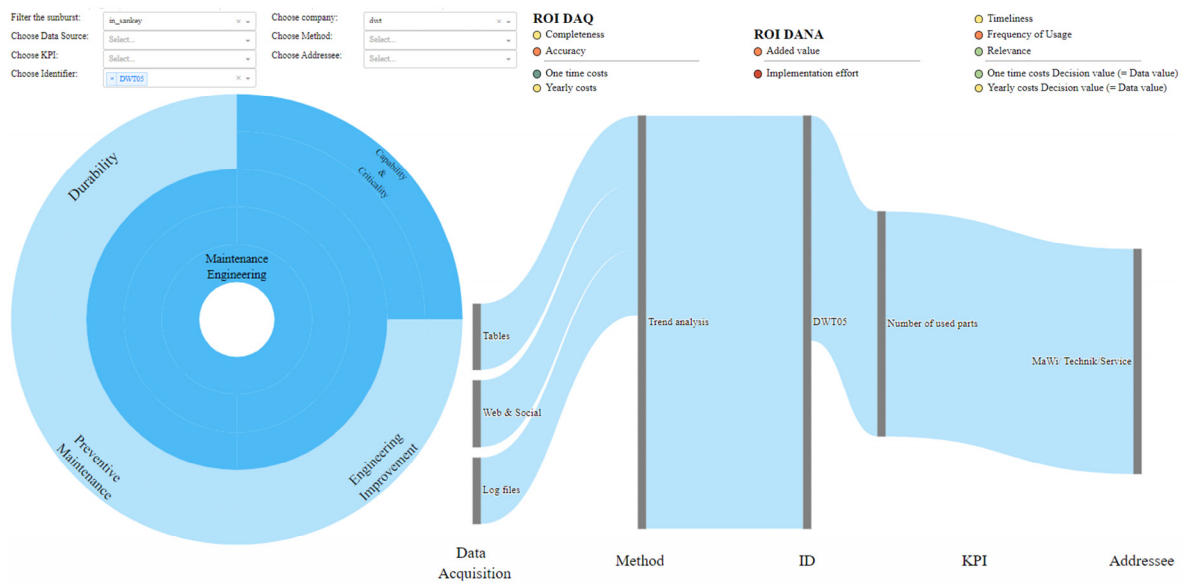


Abb. 3.13: Detailansicht auf Datenproduktebene

In Abb. 3.13 ist über eine einfache Ampelauswertung zu erkennen, ob die verschiedenen Bestandteile der Datenwertschöpfungskette *im grünen Bereich* oder verbesserungswürdig sind. Die Skalierung definiert sich über das vorab erläuterte Bewertungsmodell. Hier wurden für die verschiedenen Auswahlmöglichkeiten zur Bewertung durch Anwendende Skalen mit Euro-Werten und einem Farbcode versehen. Über diese Auswahl und Filtermöglichkeiten lässt sich die Datenwertschöpfungskette aufschlüsseln und analysieren. So kann daraus eine *Geschichte* über die Datenwertschöpfungsketten und Datenprodukte einer Organisation *erzählt* werden. Geschichten (Storytelling) veranschaulichen Sachverhalte, die durch Theorien lediglich unzureichend zu beschreiben sind, um umfassendere Konzepte zu vermitteln (vgl. Gelman und Basbøll 2014, S. 551). So können Geschichten genutzt werden, um Hypothesen zu testen und Schwachstellen in einem Modell zu identifizieren oder zu erklären (vgl. Gelman und Basbøll 2014, S. 548).

4 Grundlagen zur Evaluation innerhalb der Anwendungsdomäne

In *WiSA Big Data* wurden 53 individuelle Online-Meetings abgehalten, um den Istzustand der Projektpartner Deutsche Windtechnik, Ocean Breeze, Iberdrola und Vattenfall zu erfassen. Bei den Evaluationsteilnehmenden musste es sich um erfahrene Anwendende aus den Organisationseinheiten handeln, die praktisch mit Ergebnissen von Datenanalysen arbeiten oder arbeiten könnten. Dabei wurden 184 Datenprodukte durch die Kreativitätstechnik QuestionStorming identifiziert; Bewertungskriterien für eine Nutzwertanalyse wurden mit den Forschungs- und Industriepartnern definiert und anhand der Nutzwertanalyse die Top-3- und Top-12-Datenprodukte identifiziert. Bei dem Industriepartner Deutsche Windtechnik waren zeitweise bis zu sieben verschiedene Abteilungen in die Evaluation involviert. Im Ergebnis wurde eine klare Priorisierung der Datenprodukte erstellt. Die im weiteren Verlauf beschriebenen Grundlagen der Windenergie wurden im Rahmen der *INFORMATIK 2021 – Computer Science and Sustainability* veröffentlicht (vgl. Bendlin et al. 2021).

Idealtypisch kann bei Interviews mit Expert*innen von drei Phasen ausgegangen werden: der Planung, der Durchführung und der Analyse (vgl. Kaiser 2021, S. 161). In der Planungsphase wird der Forschungsstand untersucht und es werden die Forschungsfragen abgeleitet, die dann in einen Interviewleitfaden umgewandelt werden (vgl. Kaiser 2021, S. 161). Basierend darauf finden die Vorbereitung zur Terminvereinbarung und die Auswahl der Anwendenden/Expert*innen für die Durchführungsphase statt. In der Analysephase werden die Interviews mit Expert*innen dokumentiert und ausgewertet.

4.1 Herausforderungen

Evaluationen bringen aus zahlreichen Gründen Herausforderung mit sich (vgl. Kaiser 2021, S. 147 ff.; Kirchoff et al. 2010, S. 113 f.). Die Herausforderungen reichen von der Auswahl der geeigneten Forschungsmethoden über die Planung, Protokollierung und Datenauswertung bis hin zur Auswahl der Proband*innen als Grundgesamtheit oder Stichprobe. Die im Weiteren detaillierter erörterten Herausforderungen wurden als Inspiration für den Evaluationsprozess und die Interviews mit Expert*innen der vorliegenden Arbeit herangezogen.

Eine Herausforderung bildet die Wahl einer Forschungsmethode, die zur Beantwortung der Forschungsfrage geeignet ist (vgl. Kaiser 2021, S. 148). Bereits dann, wenn *Forschungslücken* identifiziert und in Forschungsfragen umgewandelt werden, ist es erforderlich, die Gründe zu definieren, weshalb diese Fragen durch z. B. Fragebögen oder Interviews mit Expert*innen beantwortet werden können (vgl. Kaiser 2021, S. 148). Innerhalb der Aktionsforschung bieten sich Fragebögen sowie Interviews mit Expert*innen an, um die Forschungsfragen gemeinsam mit Forschungspartnern (als Data-Scientist*innen) und Anwendenden (hier Industriepartner) iterativ zu beantworten. Viele der

vorab untersuchten Canvas-Modelle können ebenfalls als alternative Werkzeuge für strukturierte Interviews mit Expert*innen betrachtet werden.

Kirchhoff weist auf die Bedeutung einer ausreichenden Planungsphase hin, da sich Lücken in der Befragung nachträglich lediglich bedingt schließen lassen (vgl. Kirchhoff et al. 2010, S. 113 f.). Um die besten Ergebnisse aus Interviews mit Expert*innen zu erhalten, ist es relevant, die Interviews zu planen und zu terminieren, um eine geeignete Anzahl von Expert*innen als Stichproben in Bezug auf die Forschungsfrage zu erhalten (vgl. Kaiser 2021, S. 162). Da es sich um ein ressourcenintensives Unterfangen für Organisationen handelt, ist die zeitliche und örtliche Flexibilität qualitativer Interviews mit Expert*innen ebenfalls von entscheidender Bedeutung (vgl. Kaiser 2021, S. 159). Die Covid-19-bedingten Lockdowns stellten die Evaluationsdurchführung vor zusätzliche Herausforderungen. Zum einen konnten die ursprünglich vor Ort geplanten Arbeitstreffen nur online durchgeführt werden. Zum anderen befanden sich alle Industriepartner in einer kompletten Umstellung ihrer Kommunikations- und Arbeitsgewohnheiten. Daher wurde die Evaluation in einem mehrstufigen iterativen Prozess durchgeführt. Dabei kann weder jede*r befragt noch alles erfragt werden (vgl. Kirchhoff et al. 2010, S. 113 f.). Mithin erweist es sich als hilfreich, sich auf das Wesentliche zu konzentrieren, da längere Fragebögen seltener beantwortet werden und die Auswertung länger dauert (vgl. Kirchhoff et al. 2010, S. 113 f.). Um Fehlinterpretationen von Informationen aus Interviews mit Expert*innen zu vermeiden, müssen Wissenskategorien und Auswertungs-/Visualisierungsverfahren definiert werden (vgl. Kaiser 2021, S. 150). Maßnahmen zur Dokumentation und Auswertung von Interviews mit Expert*innen müssen dementsprechend festgelegt werden, so ist eine probate Nachvollziehbarkeit der Ergebnisse sichergestellt. Kaiser empfiehlt zusätzliche Pre-Tests, damit optimale Ergebnisse erzielt werden (vgl. Kaiser 2021, S. 82).

Neben den allgemeinen Herausforderungen bei Evaluationen ist es von zentraler Bedeutung, dass das erstellte Evaluationsmodell ausgewählte Herausforderungen von Data-Science-Projekten aufgreift. Dabei existieren verschiedene nichttechnische Herausforderungen, die bei Data-Science-Projektzielen auf Basis Künstlicher Intelligenz entstehen können (vgl. Kordon 2020, S. 62), so z. B., wenn das Management in der Data-Science eine *Wunderwaffe* sieht, die jedes Problem lösen kann (vgl. Kordon 2020, S. 32 f.). Neben dem verbreiteten Prinzip des *Garbage-in, Garbage-out* (GiGo 1.0) existiert eine weitere Fehleinschätzung der Erwartungen an Data-Science in GiGo 2.0 (*Garbage-in, Gold-out*) (vgl. Kordon 2020, S. 62). GiGo 2.0 beschreibt die Erwartungshaltung, aus unvollständigen oder fehlerhaften Daten fortschrittliche Analyseergebnisse zu erhalten (vgl. Kordon 2020, S. 62). Diese Fehleinschätzungen verstärken sich dort, wo Entscheidungen durch HiPPOs ohne Rücksicht auf die Daten- und Faktenlage getroffen werden (vgl. Anderson 2015). Im Fall der vorliegenden Arbeit betrifft dies die HiPPOs im Bereich des Betriebs sowie der Wartung von Onshore- und Offshore-Windparks – als mögliche Anwendende von Data-Science und datengetriebener Entscheidungsfindung könnten sie diesen kritisch gegenüberstehen. Um dieser Herausfor-

derung zu begegnen und eine bessere Befragungsplanung zu gewährleisten, sollten Anwendende von Beginn an eingebunden und mit ihrem Domänenwissen oder ihrer Methodenkompetenz zu Befragungen konsultiert werden (vgl. Kirchhoff et al. 2010, S. 113 f.). Die Auswahlkriterien für Anwendende wie der Erfahrungsgrad innerhalb einer Organisation und der persönliche Hintergrund stellen weitere bedeutende Kriterien dar (vgl. Kaiser 2021, S. 159).

Eine Evaluation ist ein komplexes Unterfangen, das am besten in einem Team durchgeführt wird, um so bessere Ideen für die Befragung und bessere Ergebnisse zu erzielen (vgl. Kirchhoff et al. 2010, S. 114). Auf diese Art und Weise den Herausforderungen zu begegnen, hilft dabei, fehlerhafte Datenerhebung, übermäßige Datenanalysen und falsche Schlussfolgerungen zu vermeiden. Mithin sollen diese Herausforderungen auf die vorliegende Arbeit übertragen und bei der Umsetzung des Evaluationsmodells berücksichtigt werden.

4.2 Planung von Interviews mit Expert*innen

Die vorangegangenen Empfehlungen und Herausforderungen wurden bei der Gestaltung der Interviews mit Expert*innen berücksichtigt. Die Planung beinhaltet einen Projektplan (siehe Abb. 4.1) mit ausreichend Zeit, um die notwendigen Meilensteine zu erreichen (vgl. Kaiser 2021, S. 162). Je enger die Zeitabstände zwischen den Interviews gewählt werden, desto effizienter können die Termine geplant und durchgeführt werden (vgl. Kaiser 2021, S. 162).




Abb. 4.1: Evaluationsplanung Interviews mit Expert*innen

Die Anzahl der Expert*innen sollte in einem angemessenen Verhältnis zur Art der Forschungsfrage und den beabsichtigten Interviewergebnissen stehen (vgl. Kaiser 2021, S. 162). Die Erstellung und Optimierung des Evaluationsmodells als primäres Artefakt ist ein notwendiges Zwischenziel zur Klärung der Forschungsfragen. Dadurch wird das eigentliche Evaluationsverfahren einfacher nachvollziehbar, was zu einer höheren Akzeptanz bei den Evaluationsteilnehmenden führt. Im Folgenden werden die relevantesten Aspekte zusammengefasst und erläutert:

Die Auswahl der Stichprobe musste repräsentativ sein, um die Forschungsfragen zu beantworten. Die Herausforderung lag dabei in der eingeschränkten Auswahl der Stichprobe durch die Industriepartner des Forschungsprojekts *WiSA Big Data*. Eine statistische Einheit oder Stichprobe wird durch Regeln aus einer wahrscheinlichen Grundgesamtheit ausgewählt (vgl. Fahrmeir et al. 2016, S. 13). Die Grundgesamtheit als Summe aller theoretisch möglichen statistischen Einheiten einer Befragung wird typischerweise nicht erreicht (vgl. Fahrmeir et al. 2016, S. 13). Um ein „möglichst getreues Abbild der Gesamtpopulation“ zu erhalten, schlagen Fahrmeir et al. eine zufällige Auswahl der Stichprobe vor (Fahrmeir et al. 2016, S. 13). Bei dieser Stichprobe sollte „jede statistische Einheit dieselbe Chance“ haben, „in die Stichprobe aufgenommen zu werden“ (Fahrmeir et al. 2016, S. 13). Durch die Teilnahme der Onshore-Betreiberfirma Deutsche Windtechnik und der großen Offshore-Windparkbetreibenden Vattenfall, Iberdrola und Ocean Breeze konnte eine repräsentative Stichprobe abgebildet werden, die verschiedene marktübliche Szenarien abdeckt. Vattenfall (7 %) und Iberdrola (6 %) werden sich laut Schätzung der Credit Suisse für 2025 damit 13 % Marktanteil im Offshore-Bereich teilen, wie vom „Manager Magazin“ (vgl. Student 2021) dargestellt. Ocean Breeze ist ein Pionier unter den Offshore-Windparkbetreiberfirmen und die Nachfolgeorganisation der BARD Engineering GmbH, die bis zu ihrer Auflösung als einzige Firma im deutschen Sprachraum Anlagenentwickler, -hersteller, -errichter und -betreiber war. Aufgrund dieser hohen Wertschöpfungstiefe bietet die Erfahrungsbandbreite dieser Betreiberin einen echten Mehrwert für die Evaluation. Die Deutsche Windtechnik als ISP ist laut eigenen Angaben „der größte unabhängige Serviceanbieter (independent service provider, ISP) für Windenergieanlagen in Europa und vermutlich auch weltweit“ (Deutsche Windtechnik AG 2020).

Es mussten eine gemeinsame Sprache und ein klares Kennzahlensystem definiert werden, um einen möglichst einfachen Evaluationsablauf sowie einen hohen Nutzungsgrad der Ergebnisse für andere Projektbeteiligte zu erreichen.

Das Kennzahlensystem sollte in Bezug auf ausgewählte technische Herausforderungen in Data-Science-Projekten abgestimmt sein. Es sollte leicht verständlich und generell anwendbar sein, damit eine Übertragbarkeit des Modells gegeben ist. Das Kennzahlensystem sollte in diesen Prozess des Evaluationsmodells eingebunden sein, damit Optimierungspotenzial evaluierbar und identifizierbar gemacht wird.

Um die Evaluationsergebnisse zu dokumentieren, wurden die Interviews mit Expert*innen protokolliert und durch eine qualitative Inhaltsanalyse dokumentiert.

Die Evaluation der protokollierten Interviews mit Expert*innen folgte einem mehrstufigen Prozess. Innerhalb dieses Prozesses wurden unstrukturierte und semistrukturierte Interviews mit Expert*innen nach der qualitativen Inhaltsanalyse codiert und ausgewertet (vgl. Mayring 2015, S. 17).

Der Evaluationsablauf musste auf die individuellen Voraussetzungen und Besonderheiten der verschiedenen Projektbeteiligten in *WiSA Big Data* abgestimmt werden. Dafür wurde die Evaluation in enger Abstimmung mit den Projektansprechpartner*innen der Industriepartner vorbereitet und der Umfang entsprechend definiert.

Bei Interviews mit Expert*innen muss der Interviewende den ausgearbeiteten Interviewleitfaden beherrschen und ihn in einer für die Evaluationsteilnehmenden – in dem Fall der vorliegenden Arbeit Anwendenden – verständliche Sprache durchgehen können (vgl. Kaiser 2021, S. 166). Bei der Durchführung sind „Flexibilität und Gelassenheit“ gefragt, da die Umstände des Interviews von den Forschenden vor Ort nicht beeinflusst werden können (vgl. Kaiser 2021, S. 161).

4.3 Durchführung der Interviews mit Expert*innen

Bei der Durchführung kann zwischen strukturierten und unstrukturierten Interviews unterschieden werden (vgl. Mohamad und Al-Saiyd 2010, S. 149). Welche Interviewform am besten geeignet ist, hängt von der Forschungsfrage ab. Forschungsfragen haben einen abstrakten Charakter, daher müssen sie zu Interviewfragen umgewandelt werden (vgl. Kaiser 2021, S. 67 f.). Um die Teilforschungsfrage TF2.³⁵ durch ein strukturiertes Interview zu beantworten, wurden im Fall dieser Arbeit in einem ersten Schritt ein Fragebogen basierend auf den verschiedenen Stufen des CRISP-DM und eine erste Datenprodukttable abgeleitet. Dafür bildeten die für die Anwendungsdomäne relevantesten Fragen aus dem *SPSS Modeler CRISP-DM Guide* von IBM eine Basis (vgl. IBM 2016, S. 5 ff.). Diese Fragen wurden um Aspekte der Betriebsführung und Instandhaltung von Assets, in diesem Fall On-shore- und Offshore-Windparks, ergänzt. Zu diesem Zweck wurden Fragen speziell zum Asset-Management aus der *PAS 55 Assessment Methodology (PAM)*.³⁶, der *ISO 55000*.³⁷ und der *AMA*.³⁸ hinzugefügt. Der daraus resultierende Fragebogen findet sich in Anhang A. Basierend auf diesem ursprünglichen Fragebogen und den Interviewergebnissen wurde die Datenprodukttable immer

³⁵ Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?

³⁶ Die BSI PAS 55:2008 ist der weltweite Standard für die optimale Verwaltung von Sachanlagen und definiert Best Practices für das Asset Lifecycle Management.

³⁷ Die internationale Norm ISO 55000 (2014) bietet einen Überblick über die Praktiken im Asset-Management. Sie beschreibt die Grundsätze und die Terminologie sowie die erwarteten Vorteile der Umsetzung im Asset-Management. Sie ist die am weitesten akzeptierte internationale Norm für Asset-Management und gilt für alle Kategorien von Assets und Organisationen.

³⁸ Das Institute of Asset-Management (IAM, Bristol, UK) hat den AMA-Rahmen (Asset-Management Anatomy) geschaffen, um das Verständnis der Vermögensverwaltung zu fördern. Darin werden Definitionen, Vorteile, Ideen, Philosophien, Vermögensverwaltungsmodelle und insbesondere Verwaltungssysteme behandelt. Der Text geht gleichsam auf die Risikoanalyse und die Entscheidungsfindung ein.

weiter verfeinert und schließlich mit dem Datenwertschöpfungsketten-Canvas als Anwenderschnittstelle abgeschlossen.

Als Anwendende sollten Vertreter*innen verschiedener Abteilungen an den Interviews mit Expert*innen teilnehmen: die Leitwarte, die für die Durchführung von Serviceaufträgen zuständige Abteilung, die Abteilung für technischen Support sowie die Abteilung für Betriebsführungs- und Instandhaltungsmanagement. Es oblag den Industriepartnern, zu bestimmen, welche Fachleute zur Teilnahme eingeladen werden sollten. Deutsche Windtechnik beteiligte die Geschäftsleitung, die Leitung der Serviceabteilung, die technische Abteilung, das Kundenmanagement, die Teamleitung der technischen Betriebsführung, den Teamleiter der Leitwarte und den Teamleiter für interne Projekte. Vattenfall hat während des gesamten Prozesses die folgenden Expert*innen eingesetzt: Data-Scientist*innen, Dateningenieur*innen, Windpark-Betriebsleiter sowie Betriebsführungs- und Instandhaltungsspezialist*innen. Während der Interviews mit Expert*innen bei Ocean Breeze waren der Systemverantwortliche für die Projektzertifizierung sowie ein Vertreter des Genehmigungsmanagements die Hauptansprechpartner. Sie zogen sowohl die kaufmännische Leitung als auch den technischen Support (Third-Level-Support) zur Befragung hinzu. Data-Science in Form von Datenvorbereitung und Datenauswertung sowie die Arbeitsvorbereitung und -ausführung (Second-Level-Support) werden bei Ocean Breeze von verschiedenen externen Lieferanten ausgeführt.

Nachdem die Fragebögen und die erste Datenproduktabelle ausgefüllt wurden, wurden in einem weiteren Evaluationsschritt mit den Evaluationsteilnehmenden der Industriepartner Arbeitstreffen veranstaltet, um Ambitionslevel für die Kategorien und Unterkategorien der EN 15341:2019 *Maintenance Key Performance Indicators* (vgl. CEN 2019, S. 10 ff.) zu definieren. Während weiterer Arbeitstreffen wurden durch QuestionStorming innerhalb der einzelnen Fachbereiche zusätzliche Datenprodukte herausgearbeitet. Um relevante Fragestellungen in Form von Datenprodukten zu identifizieren, existieren verschiedene Ansätze, die einander teilweise ähneln. Anstelle von Brainstorming können auch Fragen eingesetzt werden, um herausragende Ergebnisse zu erzielen (vgl. Gregersen 2018, S. 66 f.). Brainstorming zielt darauf ab, alles Bekannte zu einem Thema zu sammeln. Fragen hingegen bieten die Möglichkeit, auch in Bereiche vorzudringen, die sich dem*der Betrachter*in bisher noch nicht erschlossen haben, um so die Neugier in der Diskussion zu entfachen (vgl. Gregersen 2018, S. 67). Diese Technik kann analog zum Brainstorming als QuestionStorming bezeichnet werden (vgl. Dyer et al. 2011, S. 70). Alternativ existieren Rolands *Questorming*³⁹ oder Adams *QT – Question Thinking* (vgl. Adams 2019, S. 27); beide beschreiben ähnliche Methoden (vgl. Dyer et al. 2011, S. 206). Diese Arbeit beschränkt sich der Einfachheit halber auf die Vorarbeiten von Gregersen und setzt diese Methodik ein, um Fragestellungen zu identifizieren. Der Prozess, in dem das QuestionStorming Verwendung fand, wurde an das vom Right Question Institute

³⁹ Unter der angegebenen Quelle: www.pyntan.com/vri/questorm.htm nicht mehr verfügbar.

erarbeitete Rahmenwerk *Question Formulation Technique* (QFT)⁴⁰ angelehnt (vgl. Rothstein und Santana 2011). Das Ziel des QuestionStormings ist die Identifikation einer Vielzahl von Fragestellungen. Insbesondere dann, wenn mehrere Abteilungen einer Organisation involviert sind, kann die Übersichtlichkeit durch die Anzahl der Datenprodukte verloren gehen. Die identifizierten Fragestellungen sollten dabei frei gewählt werden und die Geschäftsprobleme von Organisationseinheiten bestmöglich repräsentieren. Daher wurden auch solche aufgenommen, die nicht durch Datenanalyse beantwortet werden können. Dies umfasst etwa gewünschte Auswertungen, für die Daten aktuell noch nicht vorhanden sind oder für die das Datenmanagement noch nicht existiert. Ziel des offenen Ansatzes war es, durch QuestionStorming eine große Bandbreite relevanter Fragestellungen als Grundlage für die innerhalb dieser Arbeit untersuchten Datenprodukte zu identifizieren.

So ließen sich durch das Evaluationsmodell der Datenwertschöpfungskette Datenprodukte identifizieren, die durch BI oder Data-Science abgebildet werden können. Andere Datenprodukte benötigen strukturelle Veränderungen innerhalb der Datenwertschöpfungskette der untersuchten Organisation, um Fragen diesbezüglich beantworten zu können (Data-Governance, Datenmanagement oder innerhalb der Entscheidungsprozesse). Durch eine zu starke Einschränkung der Fragestellung könnten ggf. relevante Datenprodukte übersehen oder vernachlässigt werden. Durch den hier gewählten Ansatz konnte maßgeblich dazu beigetragen werden, eine hohe Industrierelevanz im Forschungsprojekt sicherzustellen. Danach wurde das Ergebnis des QuestionStormings an die beteiligten Fachabteilungen zurückgegeben und von ihnen in internen Revisionsdurchgängen um zusätzliche Fragestellungen ergänzt. Alternativ konnten durch eine Top-down-Analyse aus vorhandenen Dashboards sowie Reports Kennzahlen und Fragestellungen abgeleitet werden.

4.4 Analyse

Die Ergebnisse können durch unterschiedliche Verfahren analysiert werden, die „grundsätzlich unter dem Begriff qualitative Inhaltsanalyse“ zusammengefasst werden können (vgl. Kaiser 2021, S. 106). Insbesondere lässt sich dabei die qualitative Inhaltsanalyse nach Mayring hervorheben, die einerseits sehr vielfältig ist und sich andererseits aufgrund ihrer Komplexität nicht für alle Anwendungsfälle gleichermaßen eignet (vgl. Kaiser 2021, S. 106). Die Auswertung dokumentierter strukturierter oder unstrukturierter Interviews mit Expert*innen gehört neben der Textauswertung etwa aus Literatur-

⁴⁰ Basierend auf dem QuestionStorming als Startpunkt werden die gesammelten Fragen im QFT-Rahmenwerk im nächsten Schritt verfeinert und anschließend priorisiert, analog zum Vorgehen in der Nutzwertanalyse (vgl. Seliya et al. 2019, S. 4 f.). Im letzten Schritt wird entschieden, was mit den relevantesten Fragestellungen geschehen soll (vgl. Rothstein und Santana 2011).

recherchen zu den Anwendungsfeldern der qualitativen Inhaltsanalyse (vgl. Mayring und Fenzl 2019, S. 633). Dabei sind einige Grundregeln zu beachten.

Zu Beginn werden Kategorien als Codes – entweder aus dem Material (induktiv) oder theoriegeleitet (deduktiv) – definiert (vgl. Mayring und Fenzl 2019, S. 634). Dabei ist auf Datensicherheit und Vertraulichkeit zu achten und Daten, die für die Beantwortung der Forschungsfrage nicht relevant sind, müssen entsprechend anonymisiert werden (vgl. Kaiser 2021, S. 115). Beim Transkribieren ist darauf zu achten, dass die Codes und Kategorisierungen klar nummeriert und nachvollziehbar dokumentiert sind (vgl. Kaiser 2021, S. 115). Im Weiteren werden die Schritte zur Durchführung einer induktiven Analyse anhand von Mayrings sogenanntem allgemeinen Ablaufmodell der induktiven und deduktiven Vorgehensweise beschrieben (vgl. Mayring und Fenzl 2019, S. 634 ff.).

Die Forschungsfrage wird in der Einleitung begründet und erläutert, nach dieser Präzisierung wird das Material ausgewählt und charakterisiert (vgl. Mayring und Fenzl 2019, S. 640). In dem Fall der vorliegenden Arbeit wird die Kategorisierung durch die Antworten auf den Fragebogen und den Anwendungsbereich bestimmt. Die Anwendungsdomäne repräsentiert die Wartung und Betriebsführung von Onshore- und Offshore-Windparks. In einem weiteren Schritt kontextualisiert das Kommunikationsmodell das Forschungsmaterial, etwa in Hinblick auf die Beziehung zwischen dem*der Erstellenden und der Zielgruppe oder auf die Bedingungen, unter denen die Texte entstanden sind (Mayring und Fenzl 2019, S. 636). Bei diesen Interviews müssen die Analyseeinheiten festgelegt werden und es muss zwischen der Codiereinheit, der Kontexteinheit und der Auswertungseinheit differenziert werden (Mayring und Fenzl 2019, S. 636).

Den kleinsten Teil eines Textes bildet die Codiereinheit. Die Kontexteinheit („Satz, Absatz, Interviewantwort, Interview ...“) ist der Textbereich, der die Codiereinheit enthält (Mayring und Fenzl 2019, S. 636). Der Umfang des auszuwertenden Materials wird durch die Auswertungseinheit bestimmt. Im induktiven Vorgehensmodell folgt die Kategoriendefinition in Form eines ersten Codierleitfadens für die Durchführung der qualitativen Inhaltsanalyse (vgl. Mayring und Fenzl 2019, S. 634). Er bestimmt das Abstraktionsniveau und die Ausprägung der Kategorien (vgl. Mayring und Fenzl 2019, S. 637). Der Generalisierungsgrad der Kategorien wird durch das Abstraktionsniveau des Codierleitfadens bestimmt (vgl. Mayring und Fenzl 2019, S. 637). Die Kategorien werden dann auf Grundlage der vorangegangenen Schritte gebildet.

Durch eine Intra-Coder-Kontrolle kann das Codiersystem verfeinert, ergänzt und überarbeitet werden (vgl. Mayring und Fenzl 2019, S. 645). Mit dem so entstandenen Codierleitfaden wird eine abschließende Analyse des Forschungsmaterials durchgeführt (Mayring und Fenzl 2019, S. 636). Zur zusätzlichen Qualitätssicherung kann ein weiterer Codierer das Verfahren wiederholen, um Übereinstimmungen als Qualitätskriterium zu identifizieren (vgl. Mayring und Fenzl 2019, S. 636 f.). Im letzten Schritt erfolgt eine quantitative Analyse (Kategorienhäufigkeit), die qualitativ-interpretativ

ausgewertet wird (vgl. Mayring und Fenzl 2019, S. 634). Im Weiteren wird die Anwendungsdomäne beschrieben; Ergebnisse der Interviews mit Expert*innen sind in das Kapitel 5 sowie in die Beschreibung der Fallbeispiele in Kapitel 6 eingeflossen und finden sich in Anhang B und C.

5 Einführung Windenergie

Nachstehend werden im ersten Unterkapitel die technischen Unterschiede von Onshore- und Offshore-Windparks beleuchtet. Aufgrund der höheren Komplexität von Logistik und Technik fokussieren die weiteren Unterkapitel auf Offshore-Windparks. In die Ausarbeitung der weiteren Unterkapitel sind Ergebnisse aus den Interviews mit Expert*innen eingeflossen (siehe Anhang C). Die Beschreibung der Projektphasen hilft dabei, die Betriebsführung und Instandhaltungsphase im Kontext der Projektlebensphasen eines Offshore-Windparks zu bewerten. Darüber hinaus werden grundlegende technische Bestandteile eines Offshore-Windparks beschrieben. Die Herausforderung besteht in der Vielfalt möglicher Kombinationen von Variablen (z. B. Wetterrisiken, Kosten der Aufgabe, Länge der Ausfallzeit, erforderliche Anzahl von Techniker*innen, Qualifikationsniveau des Personals, benötigte Fahrzeuge oder Werkzeuge usw.) in Verbindung mit komplexen Daten- und Entscheidungsstrukturen. Gemeinsam mit der Beschreibung der Kernprozesse, Rollen und der Logistik können die Fallbeispiele im nächsten Kapitel durch die Beschreibung in diesem Kapitel im Kontext der Anwendungsdomäne bewertet werden.

5.1 Unterschiede zwischen Onshore- und Offshore-Windparks

Einer der Hauptunterschiede zwischen On- und Offshore-Windparks besteht im Windertrag. Verschiedene Störfaktoren in der Umgebung der Windenergieanlagen können die Windströmung von Onshore-Windparks beeinflussen (vgl. Lynn 2012, S. 36). Die untenstehende Abbildung (siehe Abb. 5.1) zeigt schematisch, wie sich das Landschaftsbild am Aufbauort des Windparks auf den Ertrag auswirken kann. Da die durchschnittliche Windgeschwindigkeit mit der Höhe zunimmt, kann durch ein größere Nabenhöhe gegengesteuert werden (vgl. Lynn 2012, S. 36), was in Offshore-Windparks nicht im selben Maße notwendig ist.




Abb. 5.1: Onshore- vs. Offshore-Windströmung

Neben dem Windertrag besteht in der Logistik ein weiterer bedeutender Unterschied. Für den Aufbau eines Windparks auf hoher See werden Spezialschiffe wie Jack-up Vessel und Schwimmkräne benötigt. In der Betriebsführung und Instandhaltung sind etwa Service-Betriebsschiffe (SOV⁴¹), Crew-Transfer-Schiffe (CTV⁴²), Hotelschiffe oder Hubschrauber erforderlich (vgl. Bendlin et al. 2018, S. 6 f.). Die Logistik stellt mit ca. 45 % einen der größten Kostenanteile in der Betriebsführung und Instandhaltung dar (vgl. Sperstad et al. 2017, S. 334). Dasselbe gilt für einen Großkomponententausch in der Betriebsführungs- und Instandhaltungsphase. Für die Durchführung von Offshore-Arbeiten muss ein entsprechendes Wetterfenster vorhanden sein (vgl. Bendlin et al. 2021, S. 80). Zusätzlich zu der aufwendigeren Offshore-Logistik müssen die Großkomponenten von den Fertigungsstätten an Land zu den Verladehäfen transportiert werden. Für die Verladung und Ladungssicherung sind die Hersteller verantwortlich (vgl. Heidmann 2015, S. 12). Demgegenüber können Onshore-Windparks schwer zugänglich sein und benötigen neben Schwerlasttransporten ebenfalls spezielle Kransysteme. Auch die Vorbereitung des Baugrunds stellt offshore eine größere Herausforderung dar. Neben der Berücksichtigung des Baugrunds im Fundamentdesign müssen bis 100 Meter Wassertiefe überwunden werden (vgl. Roland Berger 2013, S. 11). Die daraus resultierenden Gründungsstrukturen müssen über die Lebenszeit betrieben und instandgehalten werden.

Der erste dänische Offshore-Windpark Vindeby von 1991 hat den Weg für eine neue Form der Windenergiegewinnung geebnet (vgl. Kühne 2014). Seit diesen lokalen Prototypen hat sich die Offshore-Windenergie zu einer international ausgereiften Wachstumsbranche entwickelt. Es gibt kaum ein Land mit direktem Küstenzugang, in dem nicht über Offshore-Windenergie nachgedacht wird oder aktiv Projekte verfolgt werden. Offshore-Windenergie ist damit nicht mehr aus dem modernen Energie-Mix wegzudenken. Die lokalen küstennahen Anfänge der Branche bereiteten den Weg für Windparks in tieferen Gewässern und mit anspruchsvollen Umweltbedingungen (Tropen- und Kaltklimazonen). Gleichzeitig entwickeln sich neue Unterbereiche des Markts wie Floating-Windenergie oder Umwandlung von Windenergie zu Wasserstoff (Power to X) im Offshore-Windpark. Während die Entwicklung von Onshore- zu Offshore-Windparks einst mit einem kleinen Windpark nahe der dänischen Küste begann, wurde Vindeby mittlerweile nach 25 Jahren erfolgreichem Betrieb abgebaut (vgl. Ørsted 2017), um neuen Technologiegenerationen den Weg zu ebnen.

5.2 Projektphasen Offshore-Windparks

Ein vielschichtiges Projektumfeld und komplexe Einflussfaktoren erschweren eine effiziente Entscheidungsfindung in den Projektlebenszyklen von Offshore-Windparkprojekten. Abbildung 5.2 gibt

⁴¹ Service Operation Vessel.

⁴² Crew Transfer Vessel.

einen Überblick über die vielfältigen und zahlreichen Projektbeteiligten (vgl. Wegener et al. 2016, S. 133).

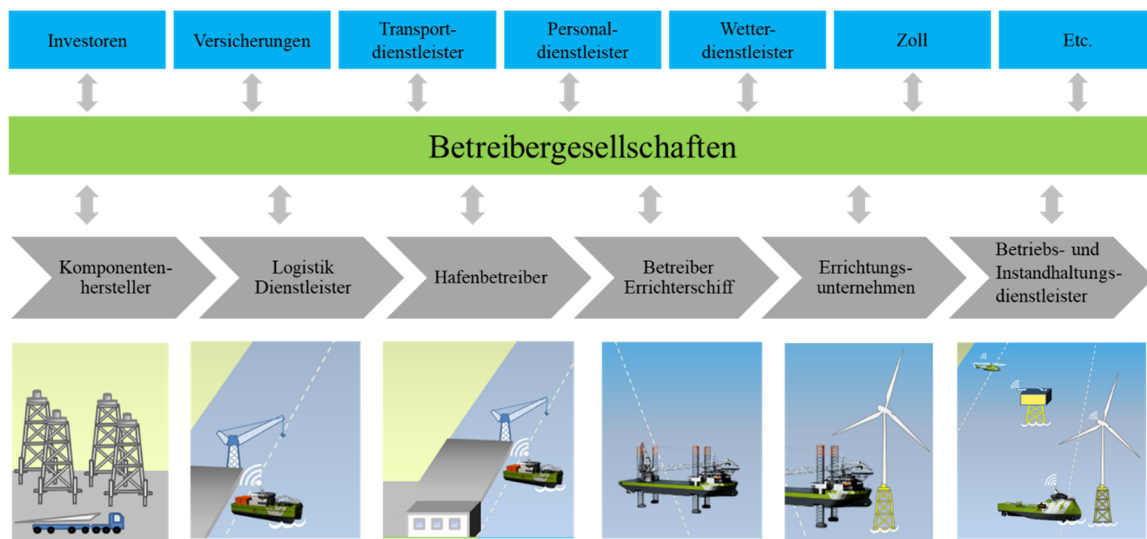


Abb. 5.2: Projektbeteiligte Offshore-Windpark (Bendlin et al. 2021, S. 80)

Die Lebenszyklusphasen (siehe Abb. 5.3) können wie folgt beschrieben werden: Innerhalb der Entwicklungsphase werden grundlegende technische Konzepte entwickelt und Flächen sowie Zulassungsverfahren diskutiert und definiert. In der Planungs- und Genehmigungsphase wird der komplette Zulassungsprozess gestartet, die Grundkonzepte des Offshore-Windparks werden entwickelt und Lieferanten sowie Hauptvertragspartner (etwa Projektfinanzierer*innen und Versicherungen) ausgewählt. In der Fabrikationsphase werden die Haupt- und Teilkomponenten des Windparks projektspezifisch ausgelegt, die Komponenten und Rohstoffe zu den Fertigungshallen transportiert und dort zu Teilkomponenten montiert. Je nach Komplexität der Haupt- und Teilkomponenten kann eine weltweite Logistikkette an Lieferant*innen und Dienstleistenden involviert sein. Bei der Transport- und Installationsphase werden zunächst die Teilkomponenten der verschiedenen Hersteller zum Vormontagehafen (Pre-Assembly Harbour) gefahren und dort vorinstalliert (z. B. Zusammenbau der Turmsegmente oder der Gondeln und Naben). Im Anschluss werden die vorinstallierten Komponenten auf die Installationsschiffe verladen und zum Offshore-Installationsstandort verschifft. Von den Installationsschiffen aus werden die Komponenten schrittweise installiert, beginnend mit den Gründungsstrukturen und der Verkabelung. Auf die Gründungsstrukturen werden die Transition Pieces montiert, die wiederum die Verbindung von der Gründungsstruktur zur Windenergieanlage herstellen. Sobald die Windenergieanlagen installiert und an den Strom angeschlossen wurden, finden finale Tests statt. Sind diese Tests der Energieübertragung abgeschlossen, gehen die Windenergieanlagen in die Instandhaltungs- und Betriebsführungsphase über. Ab diesem Zeitpunkt muss der sichere und wirtschaftliche Betrieb der Anlagen gewährleistet sein. Zum Ende der Projektlebenszeit des Offshore-Windparks – nach 20 Jahren – kann

der Rückbau eingeleitet oder eine Betriebszeitverlängerung um fünf Jahre beantragt werden (vgl. Hobohm et al. 2013, S. 25).



Abb. 5.3: Typische Projektphasen in Offshore-Wind-Projekten (vgl. Hobohm et al. 2013, S. 25; Wegener et al. 2016, S. 105, 184)

Betriebsführung und Instandhaltung: Die Betriebsführungs- und Instandhaltungsphase umfasst den zeitlich größten Bereich des Projektlebenszyklus eines Offshore-Windparks (vgl. Hobohm et al. 2013, S. 25). Der wirtschaftliche Betrieb und die technische Instandhaltung des Windparks sollen über eine Betriebsdauer von 20 bis 25 Jahren aufrechterhalten werden. Aufgrund des langen Zeitraums ergeben sich Möglichkeiten, umfangreiche Daten zu sammeln und Datenanalyse-Prozesse und -Abläufe sowie technische Komponenten zu optimieren.

Besondere Herausforderungen liegen in der komplexen Infrastruktur für die Betriebsführung und Instandhaltung. Neben der On- oder Offshore-Leitzentrale für die Einsatzplanung und das Ersatzteilmanagement ist eine komplexe Transportlogistik notwendig. Über CTV und SOV hinaus können Helikopter und für einen Großkomponententausch sogar Jack-up Vessel zum Einsatz kommen (siehe Abb. 5.4).

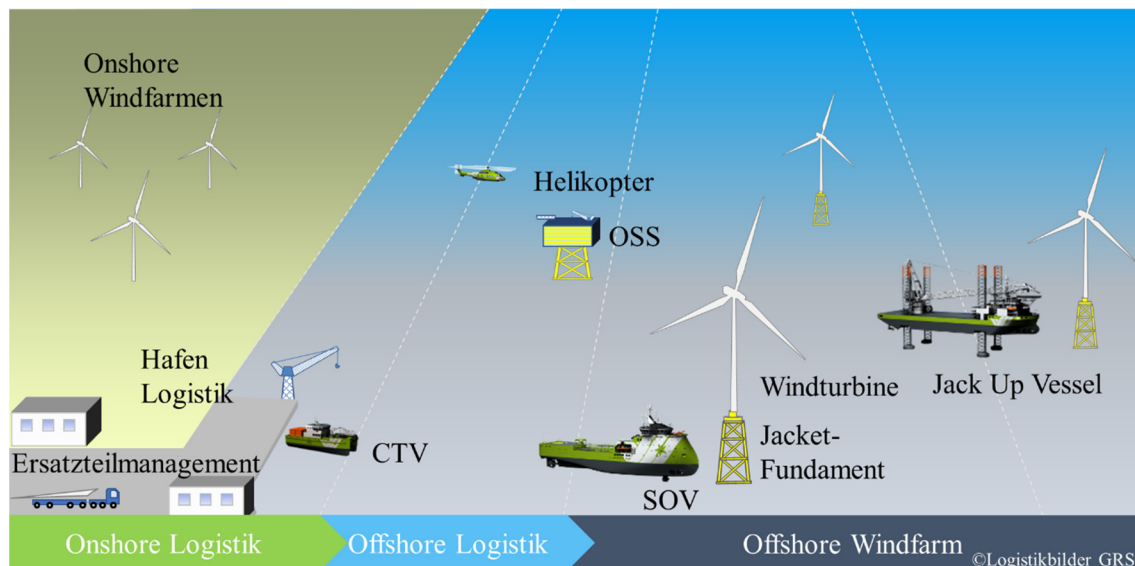


Abb. 5.4: Übersichtsgrafik Instandhaltung und Betriebsführung eines Offshore-Windparks (vgl. Bendlin et al. 2021, S. 80)

Restriktionen ergeben sich über die Umweltbedingungen wie Wellenhöhen, Windgeschwindigkeiten, Regen, Schnee, Nebel oder Temperaturschwankungen (vgl. Bendlin et al. 2016, S. 255). Das Offshore-Umspannwerk, die Jacket-Gründungsstrukturen und die Windenergieanlagen liefern während der Betriebs- und Wartungsphase unterschiedliche Sensordaten. Gleichzeitig werden

Wartungs- und Inspektionsprotokolle erstellt, die aus verschiedenen Dateitypen und Formaten bestehen können.

Die Stromgestehungskosten oder Levelized Cost of Energy (LCOE) sind eine Bewertungsgröße für Windparkbetreibende und Gesetzgeber zur Bewertung der Effizienz von Kraftwerksprojekten im Betrieb. Sie bezeichnen das Verhältnis von Gesamtkosten zu den Einnahmen durch die Stromerzeugung. Damit bieten sie ein neutrales Kriterium, um Windparkplanenden und -betreibenden eine Möglichkeit zu geben, das Geschäftsmodell ihrer Offshore-Windparks zu bewerten. In der Literatur werden verschiedene Möglichkeiten zur LCOE-Optimierung diskutiert (vgl. Ederer 2016, S. 358; Ioannou et al. 2018, S. 289). Dazu gehören beispielsweise die Optimierung der Logistikkette (Entfernung zur Küste) und die Erhöhung der Stromerzeugung, etwa durch größere Windenergieanlagentypen. So besteht eine Möglichkeit, die LCOE innerhalb von zwei seiner Bestandteile zu optimieren. Die Betriebskosten (OPEX⁴³) sowie die Investitionskosten (CAPEX⁴⁴) repräsentieren dabei den Hauptbestandteil der Gesamtkosten.

Die OPEX umfassen sämtliche Kosten für den Betrieb und die gesamte Logistik sowie die Ersatzteilbeschaffung. Dazu zählen geplante und ungeplante Wartungsarbeiten, Klein- und Großkomponententausch sowie der Transport von Ersatzteilen. Sie machen für Offshore-Windparks etwa 30 % der Kosten aus (vgl. Carroll et al. 2016, S. 1107).

5.3 Technische Bestandteile eines Offshore-Windparks

Weite Teile der Abschnitte 5.3 und 5.4 wurden auf den *BUIS-Tagen 2021* veröffentlicht (vgl. Bendlin et al. 2021). Die technischen Grundkonzepte der Onshore-Windenergie fungierten als Basis für Offshore-Windparks, weshalb sich Grundlagen übertragen lassen. Aufgrund der höheren Komplexität von Offshore-Windparks beschränkt sich die Beschreibung der Technik in dieser Arbeit auf Offshore-Windparks.

Im Mittelpunkt der Stromerzeugung von Offshore-Windparks stehen die Windenergieanlagen (siehe Abb. 5.5). Durch solide Gründungsstrukturen sind sie mit dem Boden verbunden. Die Gründungsstrukturen gewährleisten, dass die Windenergieanlagen während ihrer 20- bis 25-jährigen Lebensdauer den Umweltbedingungen wie starken Winden, hohen Wellen, Baugrundbedingungen usw. standhalten können (vgl. BSH 2015, S. 71). Die parkinterne Verkabelung verbindet das Offshore-Umspannwerk mit den Windenergieanlagen.

⁴³ Operational Expenditures.

⁴⁴ Capital Expenditures.




Abb. 5.5: Schematischer Aufbau einer Offshore-Windenergieanlage mit Gründungsstruktur
(vgl. Bailey et al. 2014, S. 9; BSH 2015, S. 19)

Es existieren grundsätzlich zwei Arten von Windenergieanlagen: getriebebestückte und getriebelose. Ein Vorteil der getriebelosen Windenergieanlagen besteht in der Reduzierung der beweglichen Teile; laut Siemens können mit diesem Design bis zu 50 % der Komponenten eingespart werden (vgl. Siemens AG 2014, S. 3). Die Hauptbestandteile beider Typen von Windenergieanlagen sind identisch. Ein Turm verbindet die Gondel, die Nabe und die Blätter einer Windenergieanlage mit dem Grundgerüst. Innerhalb der Nabe befindet sich der Generator zur Stromerzeugung, der die durch die Blätter angeregte Drehbewegung entweder direkt oder durch ein vorgeschaltetes Getriebe in Strom umwandelt. Dazu existieren für Offshore-Windenergieanlagen weitere Komponenten in Bezug auf die Zugangsstrukturen wie Bootsanleger oder Helikopter-Plattformen.

Zuverlässigkeit und Überwachung von Offshore-Windenergieanlagen: Um eine höchstmögliche Zuverlässigkeit der Windenergieanlagen zu erreichen, sind Möglichkeiten zur Fernüberwachung eingebaut. Ein Condition Monitoring System (CMS) überwacht dauerhaft den Zustand der Windenergieanlagen und meldet ihn an ein übergeordnetes Supervisory-Control-and-Data-Acquisition (SCADA)-System (vgl. Carroll et al. 2015, S. 3 f.). Über diese beiden Systeme kann der Zustand der verschiedenen Windenergieanlagen in der Windpark-Kontroll-Software eingesehen werden, um ggf. gegenzusteuern oder Fehler durch Fernwartung zurückzusetzen. Durch diese Möglichkeit in Kombination mit der automatischen Überwachung der Komponenten besteht eine dauerhafte Kommunikation der Windenergieanlagen mit den Betreibergesellschaften und Herstellern. Gleichzeitig werden relevante Hauptsteuerungskomponenten redundant ausgelegt, um durch diese zusätzliche Sicherheit Wartungseinsätze zu verringern.

Trend zu großen Anlagenklassen: Innerhalb des Markts der Hersteller für Windenergieanlagen geht der Trend zu immer größeren Windenergieanlagen. So bilden 2022 die Windenergieanlagen der

14-MW-Klasse den Stand der Technik. Auch wenn 20 MW bisher noch nicht verfügbar sind, deuten Entwicklungen darauf hin, dass größere Windenergieanlagenklassen kommen werden. Der Wechsel zu Anlagen mit größerer Nennleistung führt zu einer Reduktion der Kosten in Bezug auf die Nennleistung (vgl. FOWIND 2014, S. 26; Roland Berger 2013, S. 11) sowie zu einer direkten Reduzierung des Wartungsaufwands in der Einsatzplanung. Dem steht ein höherer Aufwand bei der Ersatzteilversorgung und -logistik gegenüber, da ggf. größere Lagerflächen oder Schiffe zum Teiletausch benötigt werden.

Zentrale Herausforderungen von Offshore-Windparks: Größere Windenergieanlagen mit größeren Komponenten und der Trend zu Offshore-Windparks mit höherer Entfernung zur Küste sind wesentliche Einflussfaktoren auf die Logistik und Wirtschaftlichkeit eines Offshore-Windparks (vgl. Baagøe-Engels und Stentoft 2016, S. 250). Die Umweltbedingungen auf hoher See stellen große Herausforderungen an die eingesetzten Komponenten (vgl. Law und Koutsos 2020, S. 1964). Neben den Wind- und Wellenlasten sind Feuchtigkeit und der korrosionsfördernde Salzgehalt der Luft zu nennen. Das Salz in der Luft wirkt ähnlich wie Hagel erodierend auf die Windenergieanlagenblätter (vgl. Law und Koutsos 2020, S. 1956). Diese beständige Belastung der Komponenten, die einen erhöhten Verschleiß bedingt, ist neben der von Wetterbedingungen abhängigen Erreichbarkeit von Offshore-Windparks eine der größten Herausforderungen für die Instandhaltung und Betriebsführung (vgl. Baagøe-Engels und Stentoft 2016, S. 250). Das komplexe Zusammenspiel unterschiedlicher Projektbeteiligter sowie deren Verständnis von Schnittstellenmanagement und Risikomanagement bilden eine erschwerende Herausforderung für Offshore-Windparkbetreibende und Servicedienstleistende (vgl. Wegener et al. 2016, S. 162).

Innerparkverkabelung: Die Innerparkverkabelung verbindet die Windenergieanlagen mit den Umspannstationen (vgl. Freeman et al. 2016, S. 13). Dabei können die einzelnen Windenergieanlagen in verschiedenen Ringen oder Strängen durch Seekabel verbunden sein (vgl. EWE ENERGIE AG 2015). Ein Vorteil der Ringverkabelung besteht darin, dass ein unterbrechungsfreier Betrieb im Ring auch dann möglich ist, wenn es zu einem Schnitt oder Kabelbruch kommt (vgl. EWE ENERGIE AG 2015). Gleichzeitig kann genau lokalisiert werden, zwischen welchen Windenergieanlagen die Kabelstörung vorliegt, was eine Entstörung deutlich vereinfacht. Bei einer Strangverkabelung würden alle an einem Strang angeschlossenen Windenergieanlagen für die Produktion ausfallen.

Wesentlich Elemente der Gründungsstruktur: Die Größe der Turbine steht in einem engen Zusammenhang mit der Anregung von Schwingungen und folglich mit den durch die Wellenbewegung erzeugten dynamischen Belastungen (vgl. Hau 2013, S. 679). Die Gründungsstrukturen müssen diesen Lasten standhalten und verbinden die Windenergieanlage mit dem Meeresboden. Monopile- und Jacket-Gründungsstrukturen werden aktuell am häufigsten verwendet (vgl. Chen und Kim 2022, S. 3). Beide Konstruktionen unterscheiden sich von der primären Stahlkonstruktion. Jacket-Gründungsstrukturen bestehen aus einem Stahltragwerk und Pfählen, die das Bauwerk im Meeres-

boden verankern. Monopiles sind eine Einzelpfahl-Stahlkonstruktion, die aufgrund ihrer Erschwinglichkeit häufig eingesetzt werden (vgl. Achmus 2011, S. 602). Beide Gründungsstrukturen umfassen auch andere Komponenten. Kolkschutz- oder Sonarmesssysteme können verwendet werden, um Kolkbildung oder Unterspülung durch Bodenveränderungen zu verhindern (vgl. Stahlmann und Schlurmann 2012, S. 299). Zu den sekundären Stahlkonstruktionen gehören Anbauten wie das J-Tube (für die Kabeleinführung), Zugangssysteme über Bootsanleger, Leitern und Zwischenplattformen (Ruheplattformen) sowie die Außenplattform, auf der auch der Davitkran montiert ist; mit diesem Kran können Lasten von den Versorgungsschiffen auf die Außenplattform gekrant werden. Bei sogenannten Suction-Buckets (Saugeimer-Gründungsstrukturen) wird durch Unterdruck eine Saugglocke am Fuß der Gründungsstruktur in den Meeresboden gezogen, was teilweise auch zur Verkürzung der Installationszeiten genutzt wird (vgl. Achmus und Schröder 2014, S. 598). Abbildung 5.6 bietet eine Übersicht über mögliche Gründungsstrukturtypen.




Abb. 5.6: Übersicht verschiedener Gründungsstrukturen in Offshore-Windparks ©Ramboll
(Bendlin et al. 2021, S. 83)

Die geläufigste Art von Gründungsstrukturen mit den niedrigsten Kosten ist das Monopile, daneben existieren Jacket-Gründungsstrukturen für Wassertiefen ab 20 m Tiefe und Schwergewichts-Gründungsstrukturen für Wassertiefen von 0–25 m (vgl. Konstantinidis und Botsaris 2016, S. 5). Bei größeren Wassertiefen werden schwimmende Gründungsstrukturen eingesetzt (vgl. Higgins und Foley 2014, S. 603). Die Wassertiefe hat einen wesentlichen Einfluss auf die Wahl der geeigneten Gründungsstrukturen (vgl. Higgins und Foley 2014, S. 603). So verlieren beispielsweise Schwerkraftgründungen mit zunehmender Wassertiefe ihre finanzielle Attraktivität. Tripods und ihre Varianten haben sich neben anderen Gründungsstrukturen noch nicht am Markt durchsetzen können.

Die unterschiedlichen Gründungsstrukturen, die durch den Standort des Windparks bestimmt werden, erfordern unterschiedliche Mengen an Stahl, was sich auf die Investitionskosten des Offshore-Windparks auswirkt. In diesem Zusammenhang haben die Kosten für die Gründungsstrukturen einen Gesamteinfluss von 18 % auf die CAPEX (vgl. Lacal-Arántegui et al. 2018, S. 134). So führt jeder zusätzliche Meter Wassertiefe zu einem Anstieg der Gründungsstrukturkosten um etwa 2 % (vgl. Gonzalez-Rodriguez 2017, S. 13).

Umspannstation: Der Umspannstation (siehe Abb. 5.7) obliegen drei Hauptaufgaben: die Notstromversorgung der Windenergieanlagen bei einem Netzausfall zu gewährleisten, den von den Windener-

gieanlagen erzeugten Strom zu sammeln und die Spannung von 33 oder 66 kV (maximal 155 kV) an die Umrichterstation der Netzbetreibenden zu übertragen (vgl. Wegener et al. 2016, S. 228).



Abb. 5.7: Umspannplattform ©Ramboll (Bendlin et al. 2021, S. 83)

Offshore-Umspannwerke bestehen aus einer Basisstruktur und einer *Topside*, die die elektronischen Teile enthält. Abgesehen von diesen Teilen gibt es sowohl bemannte als auch unbemannte Umspannwerke. In den Offshore-Windparks Global Tech I und Butendiek z. B. verfügen die bemannten Umspannwerke über Räume zum Essen, Entspannen und für die Freizeit sowie über Schlafkabinen für die Besatzung und Besuchenden. Die Umspannwerke weisen zum Teil auch Anlegestellen für Boote und Landeplätze für Hubschrauber auf.

Messmasten und -bojen: Für die Planung eines Offshore-Windparks muss die wirtschaftliche Tragfähigkeit berücksichtigt werden. Meist werden dafür Windmessmasten verwendet, es können aber auch Wind- oder Wellenmessbojen eingesetzt werden (vgl. Gottschall et al. 2017, S. 3). Zwei Offshore-Forschungsplattformen, FINO1 und FINO3, wurden in der Nordsee gebaut, und eine dritte, FINO2, wurde in der Ostsee errichtet. Diese Plattformen messen Wetterdaten und stellen sie Projektentwicklerfirmen zur Verfügung (vgl. fino-offshore.de 2019). Mithilfe der Forschungsplattformen können Wissenschaftler*innen eine Vielzahl von Umweltbedingungen analysieren. Neben Windgeschwindigkeiten, Wellenhöhen und Salzgehalt haben Forschende auch den Vogelzug und die Anzahl der Schweinswale untersucht (vgl. fino-offshore.de 2019).

Konverter-Plattform und Onshore-Substation: Die Übertragungsnetzbetreibenden, auch *Offshore-Transmission-Owner* genannt, betreiben Umspannwerke und Konverter-Plattformen an Land. Die Konverter-Plattformen sind dafür zuständig, den Strom von den verschiedenen Offshore-Wind-

parks zu sammeln, ihn umzuwandeln und an das Umspannwerk an Land zu senden. Das Umspannwerk an Land speist den Strom dann in das Übertragungsnetz an Land ein.

5.4 Prozesse, Rollen und Logistik der Betriebsführung und Instandhaltung

Das *Konzeptmodell*⁴⁵ des Instituts für Asset-Management (vgl. IAM 2012, S. 16) bildet eine probate Grundlage für die Betriebsführung und Instandhaltung von Vermögenswerten wie einem Offshore-Windpark. Das Modell (siehe Abb. 5.8) setzt sich aus sechs Hauptteilen zusammen. Der erste Teil, *Strategie und Planung*, bezieht sich auf die Ziele der Organisation und darauf, wie diese erreicht werden sollen. Im zweiten Teil, im *Asset-Management*, geht es darum, sich um diese Vermögenswerte zu kümmern. Das in dieser Arbeit entwickelte Modell fasst diese Teile als *Management/Asset-Management* zusammen. Beim Asset-Management geht es darum, zu bewerten, wie und weshalb sich Entscheidungen auf die Lebensdauer einer Anlage auswirken. So können beispielsweise Entscheidungen, die während der Transport- und Installationsphase getroffen werden, Einfluss auf die Betriebs- und Wartungsphase haben. Der Bereich des Asset-Managements sorgt dafür, dass relevante Risiken und Informationen stets unter Kontrolle sind. Im nächsten Abschnitt *Asset-Information* sind alle Rohdaten zu finden, die während des Betriebs, der Verwaltung und der Wartung von Offshore-Windparks anfallen. Die Gruppe *Organisation und Menschen* bezieht sich auf die Organisation und die sie unterstützenden Aktivitäten, z. B. die Ressourcenplanung. Der Kreis schließt sich mit der letzten Gruppe *Risiken und Überprüfung*, die auf die Risiken fokussiert, damit die strategischen Ziele als Reaktion darauf geändert werden können.

⁴⁵ Das Konzeptmodell ist eine grafische Zusammenfassung der laut Institut für Asset-Management relevantesten Konzepte des Asset-Managements sowie von deren Zusammenspiel (vgl. IAM 2012, S. 16 f.).

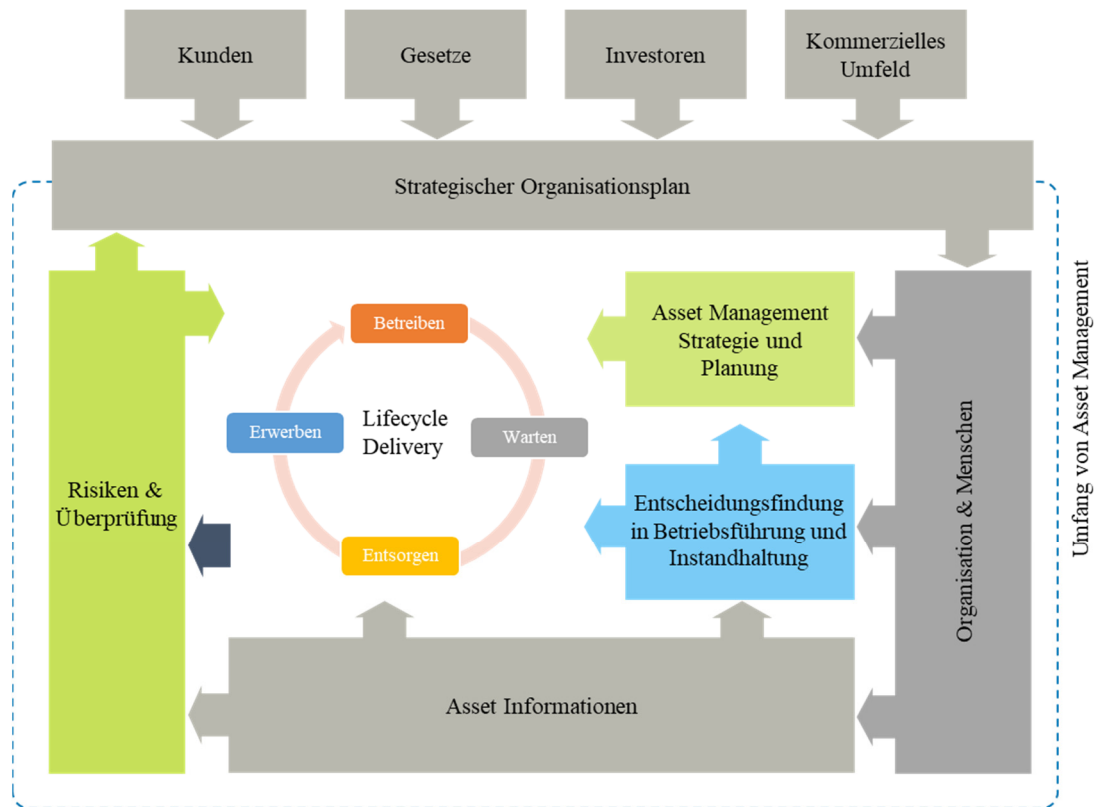


Abb. 5.8: IAM-Konzeptmodell für Asset-Management (vgl. IAM 2012, S. 16)

In der Betriebsführungs- und Instandhaltungsphase eines Offshore-Windparks sind die Transport- und die Installationsinfrastruktur komplex. Aus diesem Grund muss das Modell domänenspezifisch angepasst werden. Die Logistik in Offshore-Windparks steht vor der Herausforderung, verschiedene Gewerke mit unterschiedlichen Unterauftragnehmern zu integrieren. Hierbei können Geschäftsprozesse verschiedener Organisationen innerhalb der logistischen Wertschöpfungskette abweichen, sodass Zielkonflikte entstehen, die durch Schnittstellenmanagement adressiert werden müssen (vgl. Heidmann 2015, S. 46 ff.; Wegener et al. 2016, S. 69 ff.). In der Betriebsführung von Offshore-Windparks finden sich unterschiedliche logistische Konzepte. Diese hängen von der Entfernung zur Küste und den Umweltbedingungen am Standort des Offshore-Windparks ab.

Betriebsführung und Instandhaltung von Offshore-Windparks bergen hohe Risiken aufgrund von Umwelteinflüssen⁴⁶ (vgl. Endrerud et al. 2014, S. 1712). Um diese Risiken zu reduzieren, müssen Logistikstrategien an Umweltrisiken angepasst werden.

⁴⁶ Das Wetterrisiko und dessen Simulation hängen stark von eingesetzten Schiffen und deren Betriebsgrenzen ab. Höhere Einsatzgrenzen der Schiffe verringern die Zugangsrisiken bei schlechteren Wetterbedingungen. Am häufigsten werden dabei CTVs verwendet. SOVs können bei Wellenhöhen von bis zu 2,5 m betrieben werden, was die Anzahl der Wetterfenster für potenzielle Offshore-Arbeiten erhöht (vgl. Wolken-Möhlmann et al. 2016, S. 519).

Der Fall des Großkomponententauschs ist mit der Logistikinfrastruktur der Installationsphase und ihren Herausforderungen vergleichbar (vgl. Heidmann 2015, S. 40). Zunächst müssen die Teilkomponenten über Land oder Wasser zum Vorinstallationshafen geliefert werden. Dort werden die Komponenten vorinstalliert, teilweise in eigens dafür gefertigten Produktionshallen. Sobald die Komponenten vorinstalliert sind, werden sie an die Kaikante transportiert und von dort auf die Installationsschiffe verladen.

Um die Logistik von Offshore-Windparks⁴⁷ zu optimieren, sind Routen- und Einsatzplanung relevante Aspekte (vgl. Dai et al. 2015, S. 15). Beim bekannten Travelling-Salesman-Problem liegt der Schwerpunkt auf der Ermittlung einer optimalen Route, beispielsweise einer*ines Vertriebsmitarbeitenden. Gleichwohl vereinfacht das Optimierungsproblem die Logistik eines Offshore-Windparks zu sehr. Innerhalb eines Offshore-Windparks kann ein Boot mehrere Technikteams auf verschiedenen Windenergieanlagen absetzen und sie nach erfolgreicher Abarbeitung der Aufgaben wieder einsammeln. Es existieren auch weitere Ansätze, z. B. das Dial-a-Ride-Problem, das auch Qualitätskriterien wie die maximale Routendauer adressiert, oder das Travelling-Repairman-Problem, das auf die Minimierung der Wartezeit zur Fehlerbehebung ausgelegt ist (vgl. Irawan et al. 2017, S. 78).

Es existieren verschiedene Betreibergruppen. Eine Betreiberfirma deckt die Bereiche Anlagenentwicklung, Fertigung, Projektentwicklung, Installation, Betrieb und Wartung ab. Eine andere ist von den Windenergieanlagenlieferanten abhängig und weist Abteilungen für Projektentwicklung, Betriebsführung und Wartung auf, in denen technische Fragen geklärt werden. Windparkportfolios mit Windenergieanlagen von verschiedenen Herstellern sind eine Herausforderung. Es ist daher vonnöten, die vertraglichen Verantwortlichkeiten und Beziehungen zu überwachen. Verschiedene Arbeiten diskutieren ausführlich die typischen Schnittstellen von Offshore-Windparks (Greiner et al. 2015, S. 55; vgl. Phillips et al. 2013, S. 3; Wegener et al. 2016, S. 164 f.). In enger Interaktion mit den *WiSA*-Industriepartnern wurden die IAM-Standards und die theoretischen Grundlagen zusammengefasst, woraus sich Abb. 5.9 ergab. Die Prozesslandkarte zeigt die zentralen, externen Einflüsse der Organisation. Für das Management sind vor allem rechtliche Anforderungen und externe Partner*innen von Interesse. Sensordaten von SCADA-, CMS- und SHM-Systemen fließen ebenfalls mit ein. Den inneren Kern der Prozesslandkarte stellen das Betriebsmanagement und die Wartung dar. Anlagen senden der Leitwarte Fehlermeldungen (Servicelevel eins). Die Leitwarte überwacht die Anlagen per Fernzugriff, um Fehler zurückzusetzen. Gelingt dies nicht, wird Servicelevel zwei benachrichtigt. Diese Ebene koordiniert die Vor-Ort-Wartung und die Fehler-

⁴⁷ Die Logistik für Offshore-Windparks umfasst die Onshore-Transportlogistik, z. B. Lkw für Schwerlasttransporte von Teilkomponenten und Kräne, aber auch die Offshore-Logistik mit verschiedenen Spezialschiffen und ggf. Helikoptern. Neben den reinen Miet- oder Charterkosten fallen im Weiteren Kosten für Flug- und Fahrzeugführende, eine Crew oder technische Spezialist*innen an.

behebung mit den Servicestufen eins und drei. Der technische Support erleichtert dieses Verfahren (Stufe drei). Sie wird für schwierige technische Vorabklärungen oder langfristige industrielle Weiterentwicklungen eingesetzt. Das Feedback zum Prozess wird zur Optimierung der strategischen Planung genutzt.

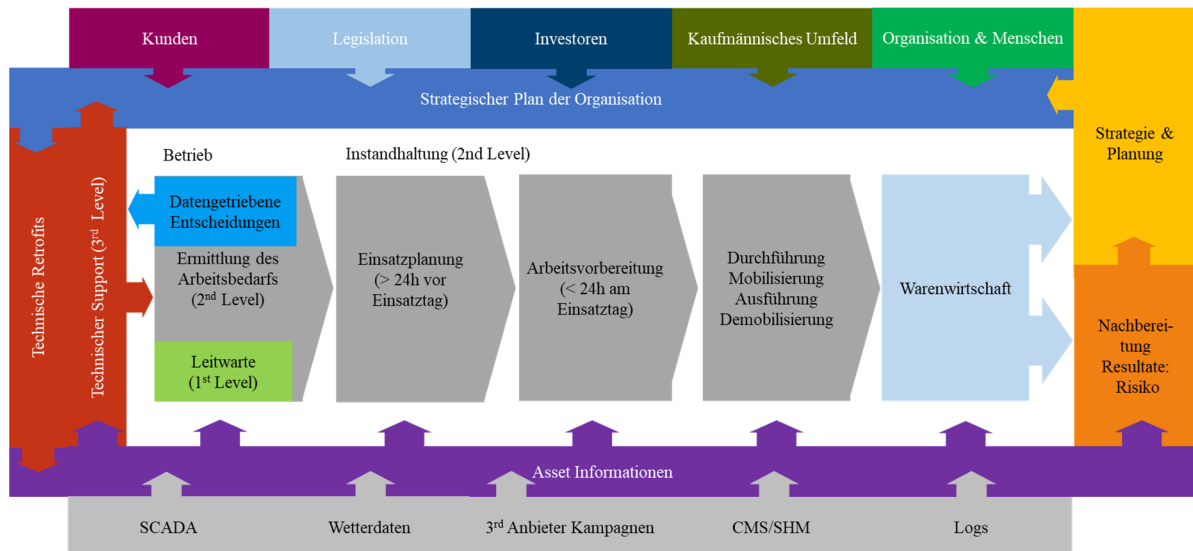


Abb. 5.9: Prozesslandkarte Betriebsführung und Instandhaltung (Bendlin et al. 2021, S. 82)

Im Folgenden wird erörtert, wie die wesentlichen Primärfunktionen in diesem Prozess miteinander interagieren; die Beschreibungen basieren dabei auf Vorarbeiten (vgl. Bendlin et al. 2021, S. 83 f.) und den Interviews mit Expert*innen (Anhang C).

Leitwarte und Einsatzzentrale (First-Level-Support): Damit Offshore-Windparks funktionieren und in einem hervorragenden technischen Allgemeinzustand bleiben, muss der Anlagenzustand regelmäßig überprüft werden (First-Level-Support). Die Zustandsüberwachung wird in Leitwarten und Einsatzzentralen durchgeführt. Dafür werden bemannte Offshore-Umspannstationen oder Leitwarten an Land eingesetzt, um die Signale der SCADA-Systeme auszuwerten. Über diesen Zugang zu den Maschinen und Echtzeitdaten führt die Leitwarte eine Fernwartung zur Problembeseitigung durch. Ist die Fernwartung nicht erfolgreich, wird ein Ticket für den Second-Level-Support erstellt, um das Problem vor Ort zu beheben. Die Leitwarte hat Zugang zu den Einsatzplänen und kann die laufenden Arbeiten einsehen.

Arbeitsvorbereitung und -ausführung (Second-Level-Support): Die Offshore-Arbeiten werden von der Arbeitsvorbereitung geplant und mit einer Priorität versehen. Sie stellt die technischen Teams zusammen und gibt die Verfahren sowie Risikobewertungen (Risk Assessment and Method Statement) für jede Aufgabe vor (vgl. Wegener et al. 2016, S. 227). Ist die Materialwirtschaft erforderlich, wird sie einbezogen. Die Arbeitsvorbereitung erteilt die Serviceaufträge und überwacht ihre Ausführung (vgl. Wegener et al. 2016, S. 227). Die Arbeitsvorbereitung bzw. -planung und -ausführung hat einen Bedarf an 12-, 24-, 48- und 72-Stunden-Daten zur Vorausplanung und zum Melden innerhalb

der Organisation. Es gibt geplante Wartungen, Inspektionen und wiederkehrende Prüfungen. Ein Teil dieser Arbeiten wird bereits digital vor Ort dokumentiert. Werden bei diesen Tätigkeiten Mängel festgestellt die nicht behoben werden können, erfolgt die Übergabe an hochqualifizierte Entstörungsteams über eine Restepunktliste, die diese Punkte abarbeiten und die Anlagen bei Bedarf entstören.

Technischer Support (Third-Level-Support): Dieser Bereich hilft bei der technischen Arbeitsvorbereitung, der Ursachenanalyse sowie der Fehlerbeseitigung (vgl. Wegener et al. 2016, S. 226 f.). Langfristige Optimierungen und die Beurteilung von Serienproblemen gehören zu den Aufgaben. Auch die Planung eines Großkomponententauschs erfordert die Expert*innen des technischen Supports. Der technische Support hat einen Bedarf an historischen Zeitseriendaten (ab 72 h), er legt Parameter zur Datenbewertung fest und gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Durch diese Abstimmung sinkt der Aufwand im Second-Level-Support. Ist eine Fernwartung nicht möglich, erstellt der technische Support auch Instandhaltungsaufträge für die Arbeitsvorbereitung und -ausführung.

Asset-Management: Das Asset-Management konzentriert sich darauf, die Ziele einer Organisation durch optimale Ausnutzung der Wertschöpfung aus dem Anlagenbestand (Assets) zu erreichen. Die Verwaltung der technischen Betriebsführung und der Instandhaltung gehören zusammen mit der Geschäfts- und Finanzverwaltung zu ihrem Aufgabengebiet. Organisationen können nachweisen, dass sie ihre Anlagen effektiv verwalten, indem sie Fachwissen und Technologien des Asset-Managements einsetzen. Um die Organisationsziele zu erreichen, strategische Entscheidungen in den Betrieb einzubinden und Aktivitäten zur Korrektur oder Verbesserung von Abläufen zu planen, einzuführen und zu kontrollieren, ist das Asset-Management mit allen drei Betriebsführungs- und Instandhaltungsebenen verbunden.

Management: Das Management legt die Strategie fest und stellt sicher, dass Verordnungen, Richtlinien und Gesetze, die für den Betrieb erforderlich sind, befolgt werden. Innerhalb der Instandhaltung und Betriebsführung können verschiedene Strategien zum Einsatz kommen. Die DIN EN 31051 *Fundamentals of maintenance* (vgl. DIN 2019, S. 12) definiert Strategien wie Wartung, Inspektion, Instandsetzung und Verbesserung bzw. Schwachstellenbeseitigung (oder Retrofitting). Diese Strategien sollen den Werterhalt und die Funktionsfähigkeit der Anlagen sicherstellen. Durch die kontinuierliche Überwachung der Stromerzeuger erfolgt ein Abgleich zwischen einem definierten Soll- und dem Istzustand. Die technische Anlagenüberwachung besteht dabei aus CMS-, SCADA- oder SHM-Systemen (vgl. Wegener et al. 2016, S. 221 f.).

Ein tägliches Dashboard liefert eine Übersicht über den Windparkstatus und aktuell laufende Einsätze. Um die Zustände effektiv überwachen zu können, werden KPIs definiert. Generell lassen sich diese KPIs in zwei Gruppen einteilen: in externe (solche, die sich auf vertragliche Anforderungen beziehen, z. B. Vertragsstrafen bei Nichtverfügbarkeit) und interne (leistungsbezogene,

technische oder organisatorische). Der relevanteste KPI ist die Verfügbarkeit, die in Form von Energie, Umsatz oder Zeit gemessen werden kann. Ein weiterer bedeutender KPI ist die *Leistung gemäß der Nennleistungskurve*, mit der gemessen wird, wie gut das System funktioniert. Bei den technischen KPIs stehen zunächst die Datenverbindung und der Zustand des Systems im Vordergrund. Danach geht es vor allem um die Fehleranalyse (Art, Häufigkeit und Fehlerraten), die Früherkennung sowie die Bestimmung der Auswirkungen von Fehlern auf die Verfügbarkeit, indem Aspekte wie die mittlere Reparaturzeit betrachtet werden. Muss ein Teil ausgetauscht werden, ist zu klären, ob ein Garantieanspruch besteht. Organisatorisch wird die Effizienz der verschiedenen Betriebsteams gemessen und verglichen, um Gründe für Verzögerungen bei der Wartung zu untersuchen.

Arbeitsabläufe: Interne und externe Stakeholder haben jeweils ihre eigenen organisatorischen Prozesse, ihre eigenen Vorgaben und Anforderungen, vertraglichen Rechte und Pflichten. Spezifikationen und Verträge sowie regelmäßige Statusbesprechungen gewährleisten, dass alle Beteiligten das tun, was sie tun sollen. Aufgrund von Datenschutzrichtlinien kann es sich als schwierig erweisen, Informationen auszutauschen. Mithin ist es wesentlich, Kommunikationswege festzulegen und zu definieren, welche Informationen weitergegeben werden müssen und dürfen.

Datenverarbeitung: Wartungskampagnen erzeugen umfangreiche Datensätze. Diese Daten können strukturiert, semistrukturiert oder unstrukturiert, als gemittelte Werte oder in Echtzeit vorliegen. Neben den Windenergieanlagendaten (Sensordaten, Wartungshistorie inklusive getauschter Komponenten) finden sich definierte Wartungs- und Inspektionsprotokolle, die bei Entstörungen ausgefüllt werden und uneinheitlich sein können.

Fehlermeldungen aus dem Anlagensteuerungs- und Überwachungssystem können je nach System abweichen und werden von den Betreibenden teilweise für Vorhersagen genutzt. Allerdings ist zu berücksichtigen, dass Netzanforderungen zur Leistungsreduktion (*Curtailment*)⁴⁸ in Datenanalysen berücksichtigt werden müssen. Im Weiteren ist die Datenqualität nur schwierig bewertbar, wenn der*die Betreibende die Input-Daten nicht kontrollieren kann (etwa weil der Hersteller keinen Zugriff gewährt). Dies wird dadurch erschwert, dass eine Vielzahl von Datenkanälen (85–5000 je nach Anlagentyp) zur Fehleranalyse relevant sein kann. Eine weitere Herausforderung bilden Medienbrüche, da Betreibende/ISPs Auswertungen zum Teil manuell auf Basis von dezentralen Exceltabellen oder eigenen Tools durchführen.

Wartungsprotokolle und Pläne geben Informationen über Aktivitäten vor Ort; parallel ist ein Schichtblatt als Live-Dokument zur Protokollierung der Schicht geöffnet. In der Zusammenarbeit mit Drittanbietern stellt Datensicherheit indes eine große Herausforderung für den Datenaustausch dar.

⁴⁸ Unter Curtailment versteht man die Abschaltung von Windkraftanlagen durch den*die Netzbetreibenden, um eine Überlastung des Netzes zu verhindern.

Daneben existieren zahlreiche lokale Listen zur Wissensvermittlung, um die Wartungsplanung durchzuführen. Nach Abschluss der Schichten werden Feedback und Lessons Learned⁴⁹ festgehalten und in regelmäßigen Feedback-Runden besprochen. In einem Jahresgespräch werden diese in Tasks umgewandelt und anschließend bearbeitet, um etwa Wartungsprozesse zu optimieren.

Datenverwaltung: Neben einem ERP-System zur Stammdatenerfassung und -pflege steht ein Service-Management-System zur operativen Planung zur Verfügung (Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie). Dieses Standard-Setup kann durch Flottenmanagement- oder Prozessvisualisierungs-Software ergänzt werden. Materiallisten dienen als Lebenslaufakte und führen auf, welche Materialien bei der Steuerung von Anlagen verbraucht wurden. Selbst bei Standardwartungen kann es zu abweichenden Standardstücklisten kommen. In einem Windparkordner werden alle parkspezifischen Informationen und Dokumente gespeichert.

⁴⁹ *Lessons Learned* bezeichnet das systematische Sammeln gelernter Lektionen und Verbesserungsmöglichkeiten in Form einer regelmäßigen Projektstatusüberprüfung.

6 Fallbeispiele Betriebsführung und Instandhaltung Onshore- und Offshore-Windparks

Innerhalb dieses Kapitels werden das Evaluationsmodell und der Visualisierungsprototyp anhand der Fallbeispiele der vier Industriepartner – Deutsche Windtechnik, Vattenfall, Iberdrola und Ocean Breeze – des *WiSA-Big-Data*-Forschungsprojekts untersucht. Dafür werden Ergebnisse der Befragung beschrieben, bevor die Fallbeispiele für die vier Industriepartner besprochen werden. Im Rahmen von Workshops und Individualinterviews wurden relevante Fragestellungen für die datengetriebene Entscheidungsunterstützung (Datenprodukte) abgefragt. Die Ergebnisse der Befragung gingen im Originalton in die Evaluation ein, weshalb es innerhalb der Datenprodukttabellen zu einer Sprachmischung aus Deutsch und Englisch kommen kann, je nachdem, welche Sprache in der Anwendungsdomäne dominierte. Im weiteren Gespräch mit den Projektansprechpartner*innen wurden Rahmenbedingungen geklärt. Zu diesen gehörten die einzubindenden Organisationsbereiche, Manager*innen und Expert*innen. Weitere Rahmenbedingungen waren die Bewertungsvariablen und die Evaluationstiefe der Interviews.

Im Rahmen von Workshops und Individualinterviews wurden relevante Fragestellungen für die datengetriebene Entscheidungsunterstützung (Datenprodukte) abgefragt. Dazu wurden der Istzustand der industriellen Prozesse und der bei den Anwendenden bestehende Bedarf analysiert und dokumentiert. Im weiteren Gespräch mit den Projektansprechpartner*innen wurden Rahmenbedingungen festgelegt. Zu den Rahmenbedingungen gehörten z. B., welche Organisationsbereiche und Manager*innen als Expert*innen eingebunden werden sollten. Eine weitere Rahmenbedingung waren die Variablen, die zur Bewertung herangezogen werden sollten. Zusätzlich musste auch die Evaluationstiefe als Detaillierungsgrad etwa der Datenprodukte definiert werden. Die Evaluation kann *top-down* oder *bottom-up* durchgeführt werden. Beim Top-down-Ansatz werden vorhandene Reports und Kennzahlen als Ausgangsbasis für Datenprodukte gewählt. Bei einem Bottom-up-Ansatz bilden die Fragestellungen aus den Fachbereichen einer Organisation die Grundlage der weiteren Evaluation. Eine Kombination beider Ansätze ist ebenfalls möglich. Anhand dieses Vorgehens war es möglich, die Befragungen flexibel zu gestalten und sie je nach vorhandener Datenlage und individueller Zielsetzung zu erweitern bzw. zu vertiefen und gleichzeitig eine Vergleichbarkeit der Interviews sicherzustellen. Damit waren die Befragungen flexibel gestaltbar und konnten je nach vorhandener Datenlage sowie individueller Zielsetzung erweitert bzw. vertieft werden.

6.1 Fallbeispiel Vattenfall

Vattenfall ist ein großer, international tätiger Offshore-Windparkbetreiber mit Zugang zu umfangreichen Betriebsführungs- und Instandhaltungsdaten. Innerhalb dieses Konzerns waren zahlreiche Prozesse und Schnittstellen klar definiert. Auch das Datenmanagement wurde bereits durchgeführt, allerdings stark an den Besonderheiten der einzelnen Windparks ausgerichtet. Da die Betriebsführung und die Instandhaltung für die ersten Jahre während der Garantiezeit von den Anlagenherstellern übernommen wurden, war für die Anfangsphase der Offshore-Windparks lediglich ein begrenzter Zugang zu Rohdaten vorhanden. Aus diesem Grund existierte trotz einer guten Datenlage eine gewisse Unsicherheit in Bezug auf die Nutzbarkeit und langfristige Auswertungsstrategie. Dennoch gab es BI-Dashboards und -Reports, die prozessunterstützend etabliert waren, sowie eine funktionierende Software- und Hardware-Landschaft.

Evaluationsablauf und Schnittstellen: Als Hauptschnittstelle im Forschungsprojekt *WiSA Big Data* fungierte das Data-Science-Team von Vattenfall. Dieses Team war über verschiedene Fachbereiche mit den Expert*innen vernetzt und konnte so relevante Informationen zur Verfügung stellen und dabei helfen, wesentliche Datenprodukte mit den Fachbereichen zu identifizieren und zu bewerten (siehe Abb. 6.1 und Tab. 6.1).

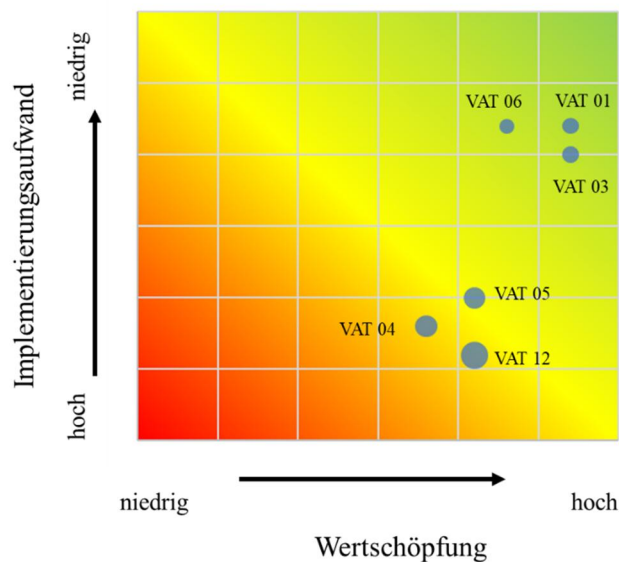


Abb. 6.1: Implementierungsaufwand vs. Wertschöpfung für Vattenfalls Datenprodukte der höchsten Priorität

ID	Welche Frage ist Kern des Datenprodukts?	Welche Entscheidung wird mithilfe des Datenprodukts getroffen?
VAT01	Is the turbine operating within the nominal range?	Is there an issue with the turbine controller settings?
VAT03	Is a blade operating with a slightly different pitch angle and inducing additional loads into the turbine which is losing power as a result?	Maintenance to correct pitch system
VAT04	How often does a specific system/component fail? Calculation should be done that a statistical valid and trustworthy number results.	Do I have a serial damage/failure? Is a specific component error prone and I need to adjust maintenance plans?
VAT05	Is the turbine operating in the correct IEC category?	Is it necessary to claim the wind turbine supplier for lost revenue?
VAT06	Are there any unusual/abnormal outliers/behavior changes detectable in the time series, e.g., temperature jumps or developments over time?	Sensor or system/component should be checked

Tab. 6.1: Übersicht der untersuchten Vattenfall-Datenprodukte

Besonderheiten: Jeder Offshore-Windpark wies aufgrund der Historie gewachsene Strukturen auf – vom Datenmanagement über die Verwaltung und das Management des Windparks bis hin zu den Entscheidungsprozessen. Wegen dieser Strukturen waren die Wartungsabläufe stark personenabhängig: Je nachdem, wer den Offshore-Windpark leitete und was die Historie vorgab, konnten deutliche Unterschiede in den Projekten auftreten. Dieses Fallbeispiel umfasst die sechs von Vattenfall als am relevantesten bewerteten Datenprodukte.

Herausforderungen: Zu den Herausforderungen für Vattenfall zählten vor allem eine Verbesserung des Datenverständnisses sowie eine Optimierung vorhandener Prozesse, um datengetriebene Entscheidungsprozesse in der Betriebsführung und Instandhaltung zu etablieren.




Abb. 6.2: Sankey-Diagramm für die höchstbewerteten Datenprodukte von Vattenfall

Das Sankey-Diagramm von Vattenfall (siehe Abb. 6.2) zeigt, dass manuelle Protokolle als Eingangsgröße für multiple Analysemethoden genutzt werden. Hierbei ergibt sich die Frage, wie hoch der Aufwand ist, um die Protokolle auszuwerten. Auf Rückfragen bei einer Besprechung der Ergebnisse stellte sich heraus, dass einige Protokolle im ERP-System gespeichert sind, andere Dateien werden von Unterauftragnehmenden automatisch oder manuell ausgewertet. Hieraus leitet sich ein Bedarf an weiterer Automatisierung und Standardisierung der Datenaufbereitung ab.




Abb. 6.3: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT01: *Is the turbine operating within the nominal range?*

Das Datenprodukt VAT01 (siehe Abb. 6.3) befasst sich mit der Frage, welche Windturbine weniger Energie (nominal Bereich) produziert als erwartet. *Anwenderbericht:* Für ein Entstörungsteam besteht eines der Ziele darin, herauszufinden, welche Windenergieanlagen unter ihrem Potenzial arbeiten, damit es eine Ursachenanalyse durchführen kann. Neben dem Entstörungsteam ist VAT01 für die Leitzentrale sowie für Data-Scientist*innen bei Vattenfall interessant. Einen wesentlichen Bestandteil der Untersuchung bildet die Wirkleistung. Es wird ein Vergleich der Soll- und der Ist-Leistungskurven vorgenommen. *Sollwerte* sind in den SCADA-Daten verfügbar und berücksichtigen den Bedarf an Netzbegrenzung (Curtailment). Ein Vergleich mit benachbarten Windenergieanlagen ist ebenfalls von Bedeutung. Um dieses Datenprodukt zu analysieren, sind Anwendende, Data Engineers sowie Data-Scientist*innen notwendig, die die Datenanalyse und ihre Interpretation unterstützen. Die Untersuchung der Datenwertschöpfungskette veranschaulicht, dass innerhalb der Datenquellen die Vollständigkeit und die Genauigkeit verbessert werden können; auch die Kosten der Datenerhebung könnten etwa durch Automatisierung verringert werden. Die Relevanz der Daten

und die späte Verfügbarkeit in Kombination mit einer hohen monetären Auswirkung ergeben einen niedrigen ROI_{DEC} .




Abb. 6.4: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT06: *Outliers in the timeseries*

VAT06 (siehe Abb. 6.4) befasst sich mit der Entdeckung ungewöhnlicher Abweichungen, die sich aus den Zeitreihendaten ablesen lassen. *Anwenderbericht:* Für ein Entstörungsteam ist es eines der Ziele, festzustellen, welche Windenergieanlagen z. B. hohe Temperaturen in ihren Komponenten aufweisen, damit es diese Bereiche auf Probleme untersuchen kann. Den Input bilden Hochfrequenz-SCADA-Daten. Dazu gehören unter anderem der Druck im Pitch-System und Temperaturwerte aus den Schaltschränken, aus der Gondel sowie von Transformator und Öl. Die Datenanalyse wird durch Data-Scientist*innen sowie durch den technischen Support unterstützt. Visualisiert werden die Ergebnisse in einem Boxplot. Bei einer genaueren Betrachtung der Datenwertschöpfungskette zeichnen sich verschiedene Optimierungsmöglichkeiten ab. Bei der Datenakquise könnten vollständigere und akkuratere Daten erhoben werden. So stellt sich in der Datenanalyse die Frage, ob die Datenqualität ausreicht und ausgeschöpft werden kann und ob die Methoden mit dem

Entscheidungswert zusammenhängen. Hier könnte Automatisierung den Aufwand verringern. Bei der Entscheidung stellt sich die Frage, ob alle Anwendenden optimal informiert sind.

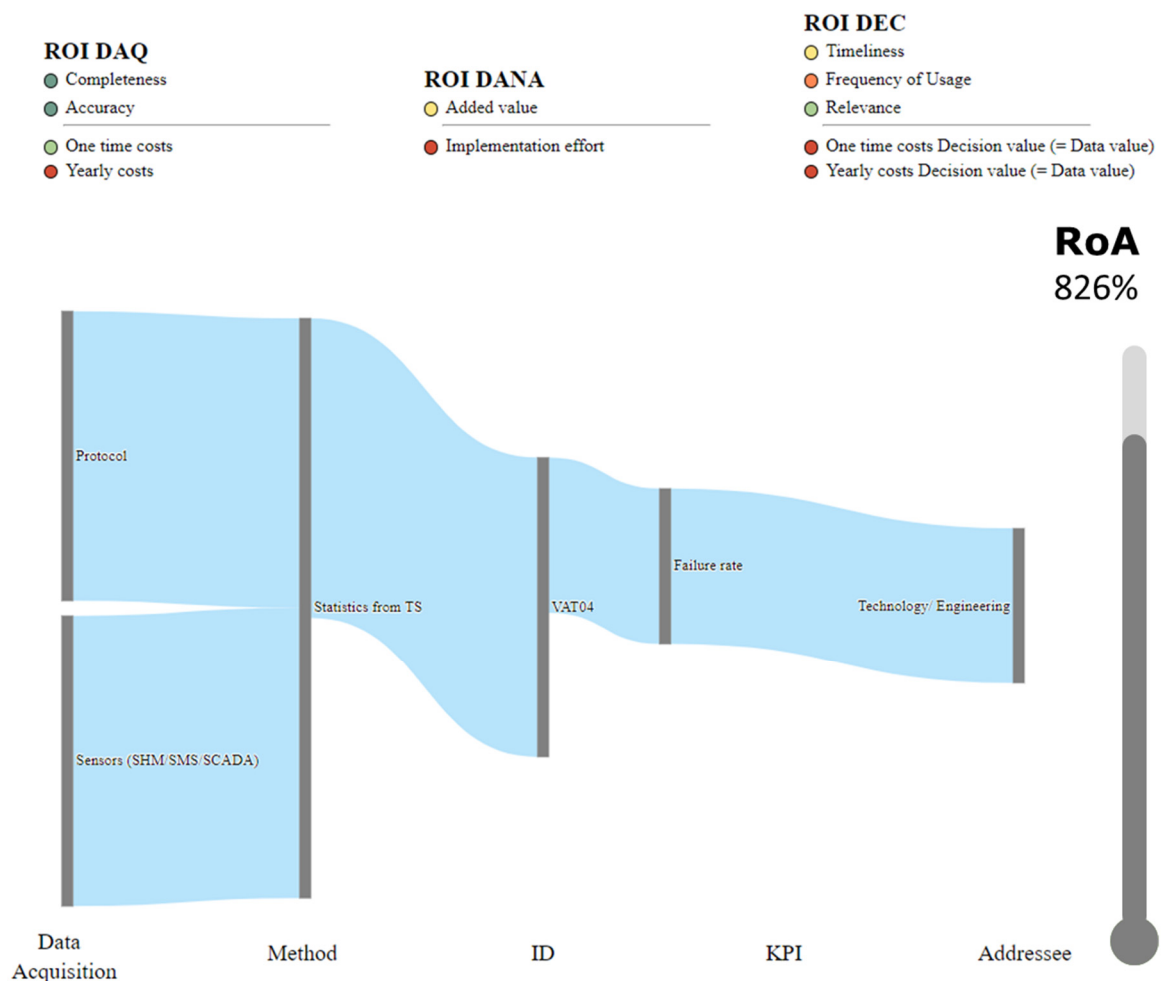


Abb. 6.5: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT04: *Component failure rate*

Das Datenprodukt VAT04 (siehe Abb. 6.5) bezieht sich auf die Frage, wie oft ein bestimmtes System oder eine Komponente ausfällt. Um dies zu beantworten, sollte eine Berechnung durchgeführt werden, die eine statistisch gültige und vertrauenswürdige Zahl ergibt. So kann entschieden werden, ob es zu wiederkehrenden Funktionsstörungen oder Schäden in den Windenergieanlagen kommt. Daraus resultierend kann die Häufigkeit der Wartungsarbeiten angepasst werden, wenn eine bestimmte Komponente häufiger ausfällt als andere. *Anwenderbericht:* Der technische Support möchte wissen, welche Komponenten oder Schäden gehäuft in den Windenergieanlagen auftreten, damit er technische Optimierungen planen kann. Spezialist*innen sowie Data-Scientist*innen helfen dabei, dieses Datenprodukt für den technischen Support zu analysieren. Ein Blick auf die Datenwertschöpfungskette zeigt, dass die jährlichen Kosten der Datenakquise verringert werden könnten, etwa durch Automatisierung. Der Implementierungsaufwand der Datenanalyse könnte ebenfalls reduziert werden.

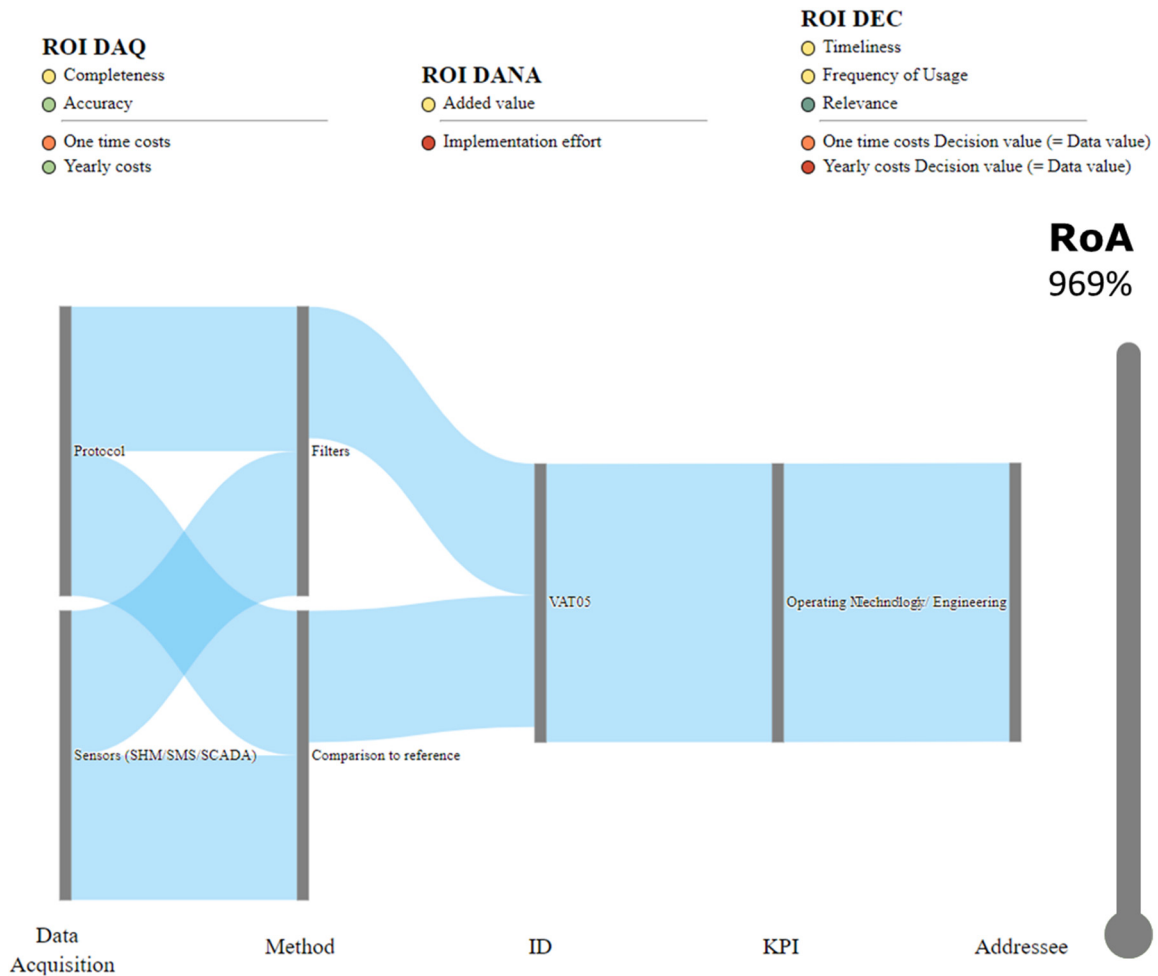


Abb. 6.6: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT05: *Is the turbine operating in the correct IEC category?*

Das Datenprodukt VAT05 (siehe Abb. 6.6) behandelt die Frage, ob die Windturbine in der korrekten IEC-Kategorie arbeitet. Dabei handelt es sich um eine Kennzahl, die für Windparks mit verschiedenen Betreiberpartnerschaften relevant ist (z. B. wenn jede*r Partner*in 50 % des Parks besitzt). *Anwenderbericht:* Der technische Support möchte wissen, ob die Windturbine in der korrekten IEC-Kategorie arbeitet, damit er die Verfügbarkeit berechnen kann. Ein weiterer Faktor, der die Berechnung von Verfügbarkeitsverlusten beeinflusst, ist die Unterbrechung der Stromversorgung. Treten Probleme mit der Turbine auf, ist der Hersteller möglicherweise nicht in der Lage, diese zu reparieren. Manuelle Inspektionen sind schwierig, da die Anzeichen für eine defekte Turbine davon abhängen, wer sie hergestellt hat und um welche Art von Turbine es sich handelt. Eine Automatisierung wurde laut Vattenfall zwar versucht, habe sich aber nicht bewährt, da die Fehlermeldungen der verschiedenen Hersteller und Software-Updates stark variieren. Die IEC-Kategorie wird manuell ermittelt. Anhand dieser bereits verarbeiteten Daten werden die von den Windkraftanlagenherstellern gemeldeten IEC-Kategorien und Verfügbarkeiten neu berechnet (Fehlerbewertung). Eine Analyse der Datenwertschöpfungskette offenbart ein hohes Optimierungspotenzial bei der Daten-

analyse. Eine Strategie könnte darin bestehen, maschinelles Lernen zu nutzen, um Datenqualität und den ROI-Werte zu verbessern.




Abb. 6.7: Sunburst- und Sankey-Diagramm für das Datenprodukt VAT12: *Lifetime extension of component*

Das Datenprodukt VAT12 (siehe Abb. 6.7) bezieht sich auf die Lebensdauer von Komponenten. *Anwenderbericht:* Der technische Support möchte wissen, ob die Betriebsdauer einer Komponente verlängert werden kann. Auf dieser Grundlage kann entschieden werden, inwiefern ein Bauteil vor dem erwarteten Ende der Lebensdauer ausgetauscht werden muss oder weiterbetrieben werden kann. Bei der Entscheidung sind hohe Folgekosten zu berücksichtigen, die ein Investment in eine bessere Datenanalyse rechtfertigen könnten. Bei der Datenwertschöpfungskette könnten die einmaligen Kosten der Datenakquise optimiert werden, bei der Datenanalyse erscheint der Aufwand bei mittlerem Mehrwert hoch.

Die gesamte Untersuchung bei Vattenfall umfasste nicht alle für das Sunburst-Diagramm definierten Kategorien (siehe Anhang F). Für ein tieferes Verständnis des Verbesserungspotenzials könnten in zukünftiger Forschung Datenprodukte der für diese Arbeit nicht untersuchten Kategorien erhoben und analysiert werden. Da allerdings innerhalb dieser Arbeit die relevantesten Datenprodukte unter-

sucht wurden, ist eine gute Repräsentativität gegeben. Nach Analyse der Datenwertschöpfungskette für Vattenfall lässt sich festhalten, dass es ratsam wäre, Datenmanagement und Data-Governance enger miteinander zu verknüpfen. Vattenfall verfügt über eine große Anzahl unterschiedlicher Windparks mit eigenem gewachsenen Datenmanagement, eigenen Schnittstellen und eigener Datenverwaltung. Die Einführung einer gemeinsamen Sprache für alle Windparks, etwa durch eine Ontologie oder Taxonomie, könnte dabei helfen, verschiedene Protokolle von Windkraftanlagen-typen und Herstellern besser zu verstehen und dadurch besser nutzbar zu machen.

Vattenfall verwaltet Daten über Data-Lakes. Innerhalb der Organisation ist die Datenverwaltung variabel und kann sich von Windpark zu Windpark ändern. Es werden Datenkataloge erstellt, um eine gemeinsame Sprache zu schaffen und die Suche nach relevanten Daten zu verbessern. Laut Vattenfall werden die Hochfrequenzdaten manuell durch den technischen Support vorverarbeitet. Es handelt sich dabei um Mitarbeitende, die ausschließlich manuelle Analysen durchführen. Sie nehmen etwa Datenfilterungen oder Schwellenwertprüfungen vor. Der*Die Site-Manager*in fungiert nicht nur als wesentliche Ressource für die Vorverarbeitung von Daten oder die Bereitstellung von Unterstützung (z. B. die Übertragung von Hochfrequenzdaten), sondern ist auch für die manuelle Durchführung vieler Bewertungen verantwortlich. Diese doppelte Rolle könnte zu Interessenkonflikten führen.

Die ausgewählten Datenprodukte sind repräsentativ für Vattenfall. Das Erkennen von Ausreißern oder die IEC-Kategorie sind beispielsweise zwei hochrelevante Datenprodukte.

6.2 Fallbeispiel Iberdrola

Bei Iberdrola handelt es sich um einen ursprünglich in Spanien aktiven Onshore-Windpark-betreiber, der mittlerweile verschiedene internationale Offshore-Windparkprojekte entwickelt und betreibt. Innerhalb des Forschungsprojekts beteiligte sich Iberdrola lediglich in Form von Interviews mit Expert*innen, die Datenwertschöpfungskette konnte mit diesem Industriepartner daher nicht bewertet werden.

Evaluationsablauf und Schnittstellen: Die Hauptschnittstelle innerhalb des *WiSA-Big-Data*-Projekts war die Data-Science-Abteilung. Mit ihr wurden verschiedene betreiberspezifische Herausforderungen und der aktuelle Entwicklungsstand von Iberdrola besprochen.

Besonderheiten: Bei Iberdrola handelte es sich um ein neues Data-Science-Team, das gerade dabei war, sich innerhalb der Organisationsstruktur zu etablieren. Damit einhergehend wurden Themen wie Datenmanagement und die mit Data-Governance verbundenen Prozesse diskutiert.

Herausforderungen: Da die ersten Jahre der Betriebsführung und Instandhaltung während der Garantiezeit durch Wartung der Hersteller abgedeckt sind, ist der Zugang zu Rohdaten für Iberdrola

entsprechend beschränkt. Damit sind lediglich eine begrenzte Interpretierbarkeit und Auswertbarkeit der Daten gegeben.

6.3 Fallbeispiel Ocean Breeze

Ocean Breeze besitzt als Nachfolgeorganisation des Windenergieanlagen- und Windparkentwicklers Bard Offshore 1 Zugang zu den Entwicklungsdaten. Dieser tiefe Zugang zu den Daten hat ebenfalls einen Einfluss auf die Betriebsführungs- und Instandhaltungsstrategie. So müssen größere Anpassungen mit den eigenen oder externen Entwickler*innen und Ingenieur*innen durchgeführt werden. Durch die damit einhergehende tiefere Wertschöpfung bestehen für Ocean Breeze die Möglichkeit und auch die Notwendigkeit, seine Datenanalysen für eine Verbesserung der Betriebsführung und Instandhaltung einzusetzen.

Evaluationsablauf und Schnittstellen: Die Hauptschnittstelle für Ocean Breeze war das interne Projektmanagement, das in der Zusammenarbeit im Forschungsprojekt beratend zur Verfügung stand und als Schnittstelle zu den internen Abteilungen diente sowie dabei half, relevante Datenprodukte mit den Fachbereichen zu identifizieren und zu analysieren (siehe Abb. 6.8 und Tab. 6.2).




Abb. 6.8: Implementierungsaufwand vs. Wertschöpfung für Ocean-Breeze-Datenprodukte der höchsten Priorität

ID	Welche Frage ist Kern des Datenprodukts?	Welche Entscheidung wird mithilfe des Datenprodukts getroffen?
OBE01	Wird der Generator in den nächsten Tagen/Wochen einen Fehler verursachen, der zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) in Hinblick auf die Rüst-/Vorlaufzeiten
OBE02	Wird das Getriebe in den nächsten Tagen/Wochen einen Fehler verursachen, der zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) in Hinblick auf die Rüst-/Vorlaufzeiten
OBE03	Wird das Hauptlager in den nächsten Tagen/Wochen einen Fehler verursachen, der zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) in Hinblick auf die Rüst-/Vorlaufzeiten
OBE04	Bestehen aktuell Fehlermuster an einer der Komponenten, die einen kommenden Einsatz vermuten lassen?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) in Hinblick auf die Rüst-/Vorlaufzeiten
OBE05	Wie verhalten sich die 10-Minuten-Statistiken im Vergleich zu den hochaufgelösten Daten, unter anderem: Ist die Annahme einer Normalverteilung legitim?	Bedarfsbezogene Einzelfallanalyse, z. B. Serienfehler, Root-Cause-Analysis Großkomponententausch
OBE06	Statistik zu Einsätzen	Nachbetrachtung der Einsatzplanung, um zur Planungsoptimierung und Kostenreduktion Muster zu identifizieren. Lernkurveneffekte, z. B. Bedarf an Großkomponenten, verbesserte Planung der Materialwirtschaft

Tab. 6.2: Übersicht der untersuchten Datenprodukte Ocean Breeze

Besonderheiten und Herausforderungen: Da die Vorgängerorganisation in dieser Form nicht mehr besteht, können zahlreiche technische Fragen nicht mehr von den ursprünglichen Entwickler*innen beantwortet werden. Dies bedeutet, dass z. B. für eine sinnvolle Ersatzteilversorgung Reverse-Engineering⁵⁰ vorgenommen werden muss. Dies gilt gleichsam für die Entstörungsarbeiten oder eine langfristige Optimierung der Anlagen. Dieses Fallbeispiel umfasst die sechs von Ocean Breeze als am relevantesten bewerteten Datenprodukte.

⁵⁰ Reverse-Engineering bezeichnet das Rekonstruieren eines bestehenden Bauteils ohne Zugang zu ausreichenden Entwicklungsdaten.




Abb. 6.9: Sankey-Diagramm Gesamtübersicht Ocean Breeze

Die Gesamtansicht der Datenwertschöpfungskette (siehe Abb. 6.9) von Ocean Breeze zeigt diverse Input-Daten, von denen viele nur als unstrukturierte Daten⁵¹ zur Verfügung stehen. Es ist schwieriger, relevante Informationen aus diesen Audio-, Video- oder Bilddateien zu extrahieren. Datenmanagement und Data-Governance sind hierbei der Schlüssel, um zu gewährleisten, dass Expert*innen wesentliche Dateien und Informationen speichern und für eine spätere Auswertung markieren können. Im Weiteren ist auffällig, dass unterschiedlichen Methoden lediglich ein geringer ROI zugewiesen wurde. Dies ist vor allem einem hohen Implementierungsaufwand geschuldet. Da Ocean

⁵¹ Die verfügbaren Daten können in drei Kategorien eingeteilt werden: unstrukturierte (black), semistrukturierte (grey) und strukturierte (white) Daten (vgl. Manyika et al. 2011, S. 33). Unstrukturierte Daten befinden sich nicht in einem *festen Feld*. Daher sind die relevanten Informationen schwieriger zu finden. Dies gilt z. B. für den Fließtext von E-Mails oder für andere Daten in Textform. Semistrukturierte Daten sind Daten mit Tags oder anderen Markierungen, z. B. XML- oder HTML-getaggtter Text. Strukturierte Daten sind eindeutig einem festen Feld zugeordnet, z. B. einer relationalen Datenbank. Sind die Koordinaten der Daten bekannt, können die Daten zur Analyse verwendet werden. Zu diesen Daten gehören unter anderem Fehlermeldungen aus ausgewerteten Sensordaten.

Breeze aktuell die Datenanalysen durch einen Drittanbieter durchführen lässt, müssten die internen Datenanalysekompetenzen massiv aufgebaut werden, um die Wertschöpfung zu erhöhen und einen langfristigen Mehrwert aus dem Potenzial der vorhandenen Rohdaten zu gewinnen.

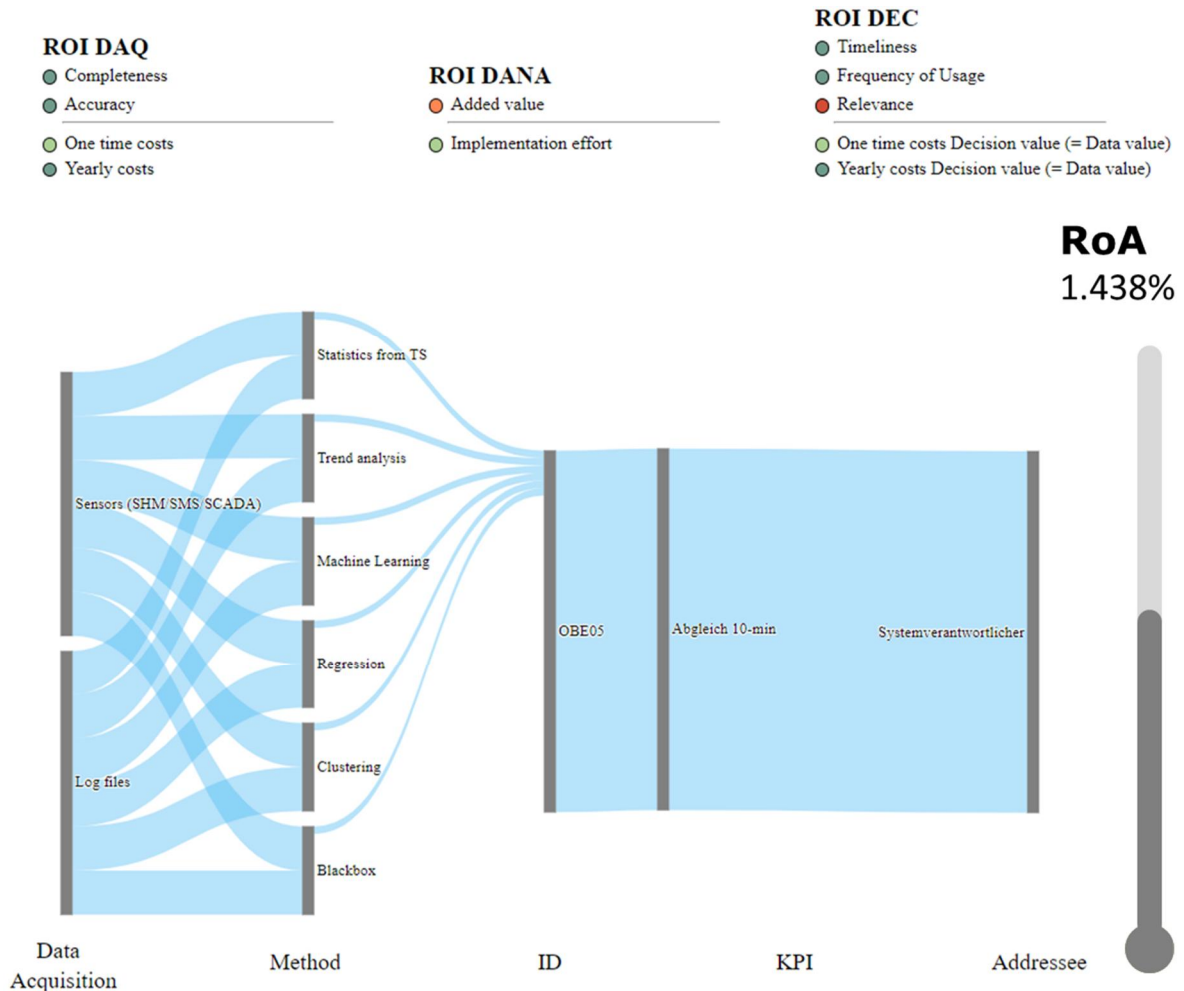


Abb. 6.10: Sankey-Diagramm Datenprodukt OBE05: *Wie verhalten sich 10-Minuten-Statistiken im Vergleich zu hochaufgelösten Daten?*

Das Datenprodukt OBE05 (siehe Abb. 6.10) bezieht sich auf die Frage, wie sich die 10-Minuten-Statistiken im Vergleich zu den hochaufgelösten Daten verhalten. Diese Fragestellung ist bei bedarfsbezogenen Einzelfallanalysen relevant, etwa bei Serienfehlern oder der Ursachenanalyse (Root-Cause-Analysis) im Fall eines Großkomponententauschs. *Anwenderbericht:* Der*die Data-Scientist*innen möchte wissen, ob hochaufgelöste Daten einen Mehrwert für seine Analysen erzeugen. Damit kann geklärt werden, ob der Aufwand der Analyse etwa durch die Annahme einer Normalverteilung reduziert werden kann. Während die vorhandenen Daten für diese Analyse ein gutes Potenzial aufweisen, sind für die Datenanalyse multiple Methoden oder Methodenkombinationen möglich bzw. erforderlich. Der Mehrwert dieser Analyse wird gering eingeschätzt; auf der Entscheidungsseite wird die Fragestellung als weniger wesentlich eingestuft und auch die

potenziellen Folgekosten werden als gering beurteilt. Trotz des hohen RoA handelt es sich daher eher um ein nachgelagertes Optimierungsziel für die Datenwertschöpfungskette von Ocean Breeze.




Abb. 6.11: Sankey-Diagramm Datenprodukt OBE01: *Wird der Generator in den nächsten Tagen/Wochen einen Fehler verursachen?*

Das gewünschte Datenprodukt OBE01 (siehe Abb. 6.11) steht exemplarisch für den Großkomponententausch. Es beantwortet die Frage, ob der Generator in den nächsten Tagen oder Wochen einen Fehler verursacht, der zu einem Wartungseinsatz führt. Das Datenprodukt wird hier weiter ausgeführt und gilt exemplarisch auch für OBE02 (Getriebe) und OBE03 (Hauptlager). *Anwenderbericht:* Der technische Support möchte wissen, ob aufgrund eines bestimmten Verhaltens der Windenergieanlagen die Planung eines Großkomponententauschs notwendig wird oder Ausfälle der Windenergieanlage zu erwarten sind. Data-Scientist*innen und Systemverantwortliche helfen bei der Analyse. Das Ziel ist eine rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) in Hinblick auf die Rüst- bzw. Vorlaufzeiten. Je nach Komponente können unterschiedliche Werte dafür genutzt werden. Das Datenprodukt ist für Ocean Breeze grundsätzlich stets interessant, lässt sich mit den vorhandenen Mitteln jedoch nicht definitiv beantworten. Es wäre ein Wunsch von

Ocean Breeze, diese Fragen für alle Großkomponenten zukünftig automatisch lösen zu können. Für den Generator werden etwa die Lagertemperatur oder Messwerte aus dem Überspannungsschutzgerät herangezogen. Die Daten sind lediglich teilweise vollständig, da keine Begutachtung vor Ort erfolgt, etwa zur Zustandsbeurteilung des Schmiersystems. Im Beispiel der Lagertemperatur beeinflusst die Frequenz der Überwachung die Kategorisierung möglicher Auffälligkeiten. Für das Getriebe könnten Temperatur- und Öldruckwerte genutzt werden. Diese Daten sind nur teilweise vollständig, da ausschließlich Remote-Daten zur Verfügung stehen. Auch hier wäre aufgrund der Folgekosten laut Ocean Breeze eine Begutachtung vor Ort sinnvoll. Bei Auffälligkeiten sollten Alarmmeldungen gegeben werden, damit eine Begutachtung stattfinden kann. Für das Hauptlager können Daten aus einem Partikelzähler herangezogen werden. Sie sind teilweise vollständig, jedoch würde Ocean Breeze aufgrund der Folgekosten bei Alarmmeldungen eine Begutachtung vor Ort durchführen. Die Analyse der Datenwertschöpfungskette zeigt ein hohes Optimierungspotenzial bei der Datenanalyse: Hier trifft eine geringe Wertschöpfung auf einen hohen Implementierungsaufwand. Die Kostenschätzung für den ROI_{DEC} beruht auf der Annahme, dass Fehler nicht erkannt werden und eine Instandsetzung notwendig wird. Hier wurde als Annahme der gravierendste Fall des Großkomponententauschs zugrunde gelegt.

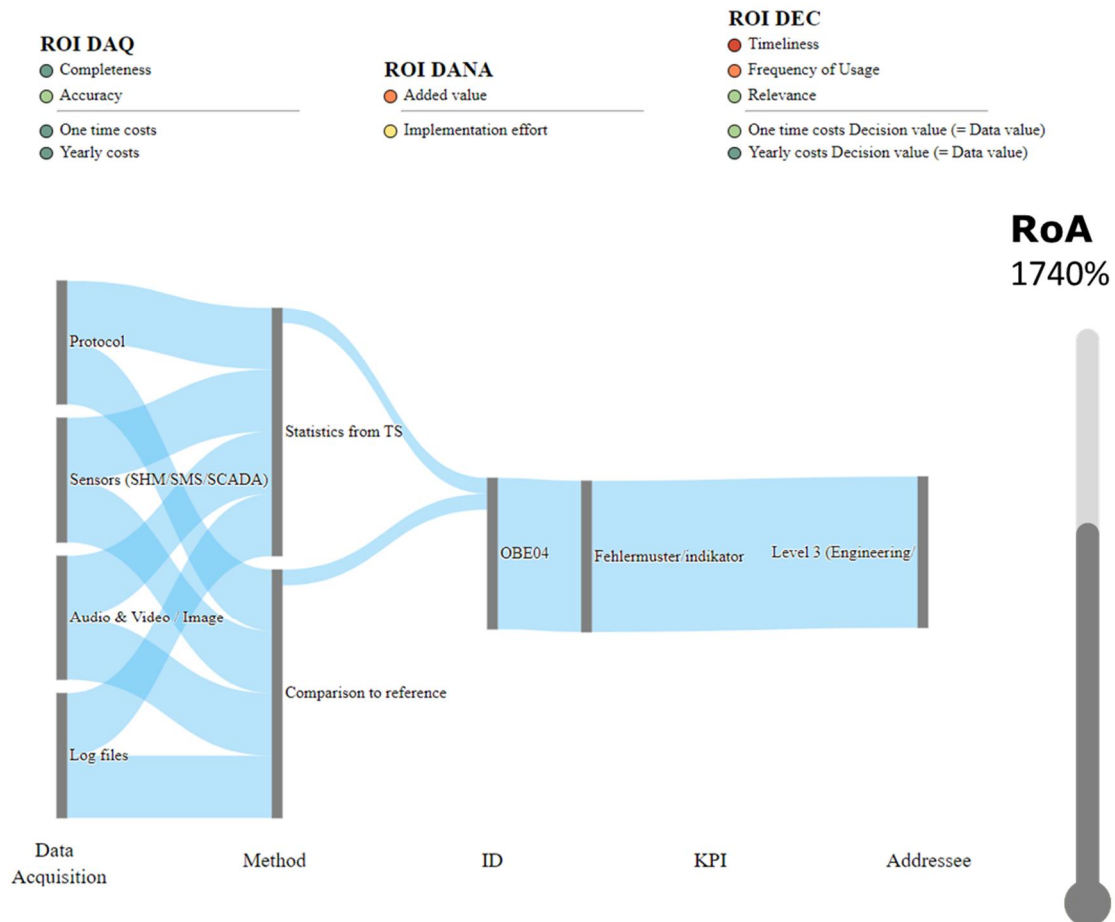


Abb. 6.12: Sankey-Diagramm Datenprodukt OBE04: *Bestehen aktuell Fehlermuster an einer der Komponenten?*

Das gewünschte Datenprodukt OBE04 (siehe Abb. 6.12) beantwortet die Frage, ob aktuell Fehlermuster an einer der Komponenten einen kommenden Einsatz vermuten lassen.

Anwenderbericht: Die Arbeitsvorbereitung möchte wissen, ob zukünftige Wartungen durch aktuelle Fehlermuster an einer Komponente ausgelöst werden könnten. Damit kann eine rechtzeitige Wartungsplanung in Hinblick auf die Rüst- bzw. Vorlaufzeiten der Entstörungsteams und der Materialwirtschaft mit Bezug auf die Verfügbarkeiten von Logistik und Komponenten für einen Großkomponententausch erfolgen. Ein Blick auf die Datenwertschöpfungskette zeigt, dass die Datenquellen ein hohes Potenzial aufweisen. Da das Datenprodukt noch nicht verfügbar ist, trifft eine hohe Wertschöpfung auf einen etwas höheren Implementierungsaufwand. Auch für dieses von Ocean Breeze gewünschte Datenprodukt wäre mithin die Verpflichtung zu einer langfristigen Datenmanagementstrategie und zum Aufbau eines größeren internen Data-Science-Teams eine relevante zu treffende Entscheidung für Ocean Breeze.

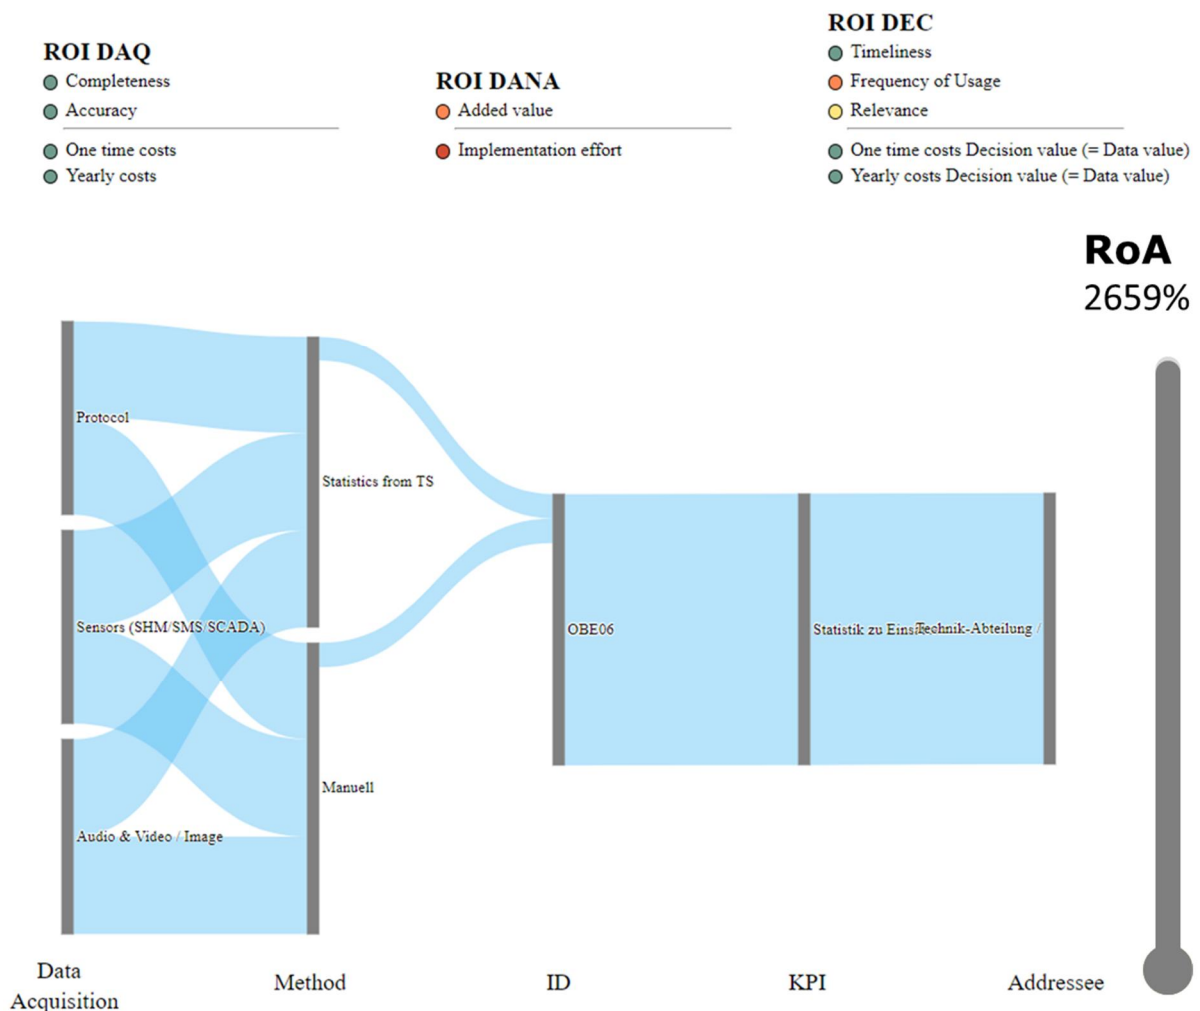


Abb. 6.13: Sankey-Diagramm Datenprodukt OBE06: *Statistik zu Einsätzen*

OBE06 (siehe Abb. 6.13) bezieht sich auf die Statistiken zu Einsätzen und die dafür genutzten Ressourcen. *Anwenderbericht:* Die Arbeitsvorbereitung möchte durch eine Nachbetrachtung der

Einsatzplanung Muster identifizieren, um Planungsoptimierung und Kostenreduktionen zu ermöglichen. So sollen die Planungen der Materialwirtschaft in Bezug auf den Bedarf an Großkomponenten verbessert werden. Dieses Datenprodukt ist für den technischen Support, die Arbeitsvorbereitung und nachgelagert auch für die Materialwirtschaft von Bedeutung. Es wird im Prozess der Planung von Großkomponententausch und in der Entwicklung technischer Verbesserungen (Retrofits) verwendet. In der Analyse wird hauptsächlich auf Expert*innen des technischen Supports zurückgegriffen. Aktuell werden dabei Excel-Analysen mit grafischer Visualisierung genutzt, etwa durch Balkendiagramme. Für die Datenwertschöpfungskette könnte eine tiefere Datenanalyse ggf. auch mit einer Methodenkombination die Wertschöpfung erhöhen und eine Automatisierung den manuellen Aufwand der Analyse verringern. So wird bei Ocean Breeze etwa der Verschleiß der Kohlebürsten am Generator bei der Jahreswartung gemessen. Daraus werden Statistiken erstellt, um den kommenden Bedarf an Kohlebürsten zu ermitteln. Für bestimmte Fragestellungen werden bei Bedarf die Wartungsprotokolle aller 80 Windenergieanlagen ausgewertet und Grafiken angefertigt, um den Materialbedarf oder kommende Wartungen zu planen. Die Genauigkeit der Daten und der Datenanalyse ist dabei abhängig von der Fragestellung.

Nach Analyse der Datenwertschöpfungskette für Ocean Breeze lässt sich festhalten, dass das Datenmanagement ein wesentliches Entwicklungsthema darstellt. In vielen Organisationen wie Ocean Breeze sind die Datenstrukturen mit der Organisation gewachsen. Damit haben sich auch die Anforderungen an das Datenmanagement verändert.

6.4 Fallbeispiel Deutsche Windtechnik

Als größter ISP für Onshore-Windparks Deutschlands verfügt die Deutsche Windtechnik über umfassende Erfahrungen und Daten. Die Deutsche Windtechnik ist im Bereich der Instandhaltung und Betriebsführung von On- und Offshore-Windparks international tätig mit einem Fokus auf den deutschen Heimatmarkt. Als geförderter Industriepartner hat die Deutsche Windtechnik mit ihrem Know-how maßgeblich zum Erfolg des Projekts *WiSA Big Data* beigetragen.

Evaluationsablauf und Schnittstellen: Die Hauptschnittstelle mit der Deutschen Windtechnik bildete das interne Projektmanagement, das in der Zusammenarbeit im Forschungsprojekt beratend zur Verfügung stand und als Schnittstelle zu den internen Abteilungen fungierte, um relevante Datenprodukte mit den Abteilungen zu identifizieren und zu analysieren (siehe Abb. 6.14 und Tab. 6.3).




Abb. 6.14: Implementierungsaufwand vs. Wertschöpfung für Deutsche Windtechnik
Datenprodukte der höchsten Priorität

ID	Welche Frage ist Kern des Datenprodukts?	Welche Entscheidung wird mithilfe des Datenprodukts getroffen?
DWT02	Welche Anlagen sind besonders auffällig?	An welchen Anlagen treten welche Fehler vermehrt auf, sodass Aktionen geplant werden und erfolgen können?
DWT05	Welche Bauteile wurden überdurchschnittlich häufig verbraucht?	Welche Bauteile müssen stärker ausgelegt werden, wo bestehen erhöhter Verschleiß und Handlungsbedarf?
DWT07	Welche Mängel gibt es an der Anlage?	Können Mängel bei anstehenden Arbeiten oder Fehlereinsätzen mit abgearbeitet werden?
DWT09	Wie ist der aktuelle Abarbeitungsstand (Nachweise)?	Damit im Nachhinein rekapituliert werden kann, ob Fehler aus vergangenen Arbeiten entstanden sein könnten.
DWT18	Welches Material könnte benötigt werden?	Wie muss die Ersatzteilplanung vorgenommen werden?
DWT32	Ist der Fehler schon häufiger aufgetreten?	Welche Fehler treten wiederholt auf?
DWT33	Welche Fehlermeldungen treten besonders häufig auf?	Serviceplanung Fehlersuche
DWT35	Welche Umrichterfehler kommen am häufigsten vor?	Informationen zur Entstörung durch die Leitwarte und die Fehlersuche
DWT36	Welche Umrichterfehler kommen an einzelnen Anlagentypen am häufigsten vor?	Informationen zur Entstörung durch die Leitwarte und die Fehlersuche
DWT58	Performt die Anlage gemäß Nennleistungskurve etc.?	Welche korrigierenden Maßnahmen müssen bei Abweichung von der Nennleistungskurve (unter vorheriger Berücksichtigung möglicher Abweichungen aufgrund von Schallreduzierung nachts, Anlagendrosselungen durch Energieversorgungsunternehmen etc.) getroffen werden?
DWT64	Welche Windenergieanlage steht?	Reset-Versuch -> nicht erfolgreich -> weiterleiten an die Technik -> kein Erfolg, Einsatz einplanen
DWT65	Aufgrund welchen Fehlers steht die Windenergieanlage?	Reset-Versuch -> nicht erfolgreich -> weiterleiten an die Technik -> kein Erfolg, Einsatz einplanen
DWT66	Wo steht die Windenergieanlage, wer ist am schnellsten da und kennt der*die Techniker*in sich mit dem Windenergieanlagentyp/-fehler aus?	Wie kann der Einsatz der Techniker am besten geplant werden?
DWT67	Um welchen Schaden handelt es sich?	Einsatzplanung

Tab. 6.3: Übersicht der untersuchten Datenprodukte Deutsche Windtechnik

Besonderheiten: Neben der hohen Offenheit und Beteiligung in den gemeinsamen Interviews und Workshops zeigte sich die Deutsche Windtechnik aufgeschlossen für Neues. Als Serviceorganisation

steht eine Verbesserung der internen Abläufe und des Datenmanagements in der Arbeit mit den Kund*innen für die Deutsche Windtechnik als Verbesserungsziel im Fokus.

Herausforderungen: Auch die Deutsche Windtechnik muss mit gewachsenen Strukturen arbeiten. Dabei müssen die Prozesse und Vorgaben mit den Anforderungen externer Kund*innen und Partner*innen verbunden werden. Die Zielkonflikte bieten Raum für zukünftige Erweiterungen und Verfeinerungen des Evaluationsmodells. Dieses Fallbeispiel umfasst die 14 von der Deutschen Windtechnik als am relevantesten bewerteten Datenprodukte, da mit der Deutschen Windtechnik eine erweiterte Datenwertschöpfungskette untersucht wurde, die Data-Governance und Datenmanagement umfasste. In den Evaluationsergebnissen mit den verschiedenen Organisationseinheiten der Deutschen Windtechnik zeigten sich Abweichungen in der Bewertung der Ambitionslevel (siehe Anhang H). Diese Abweichungen erlauben Rückschlüsse auf mögliche interne Zielkonflikte, die innerhalb dieser Arbeit aus Gründen der Einfachheit vernachlässigt werden.

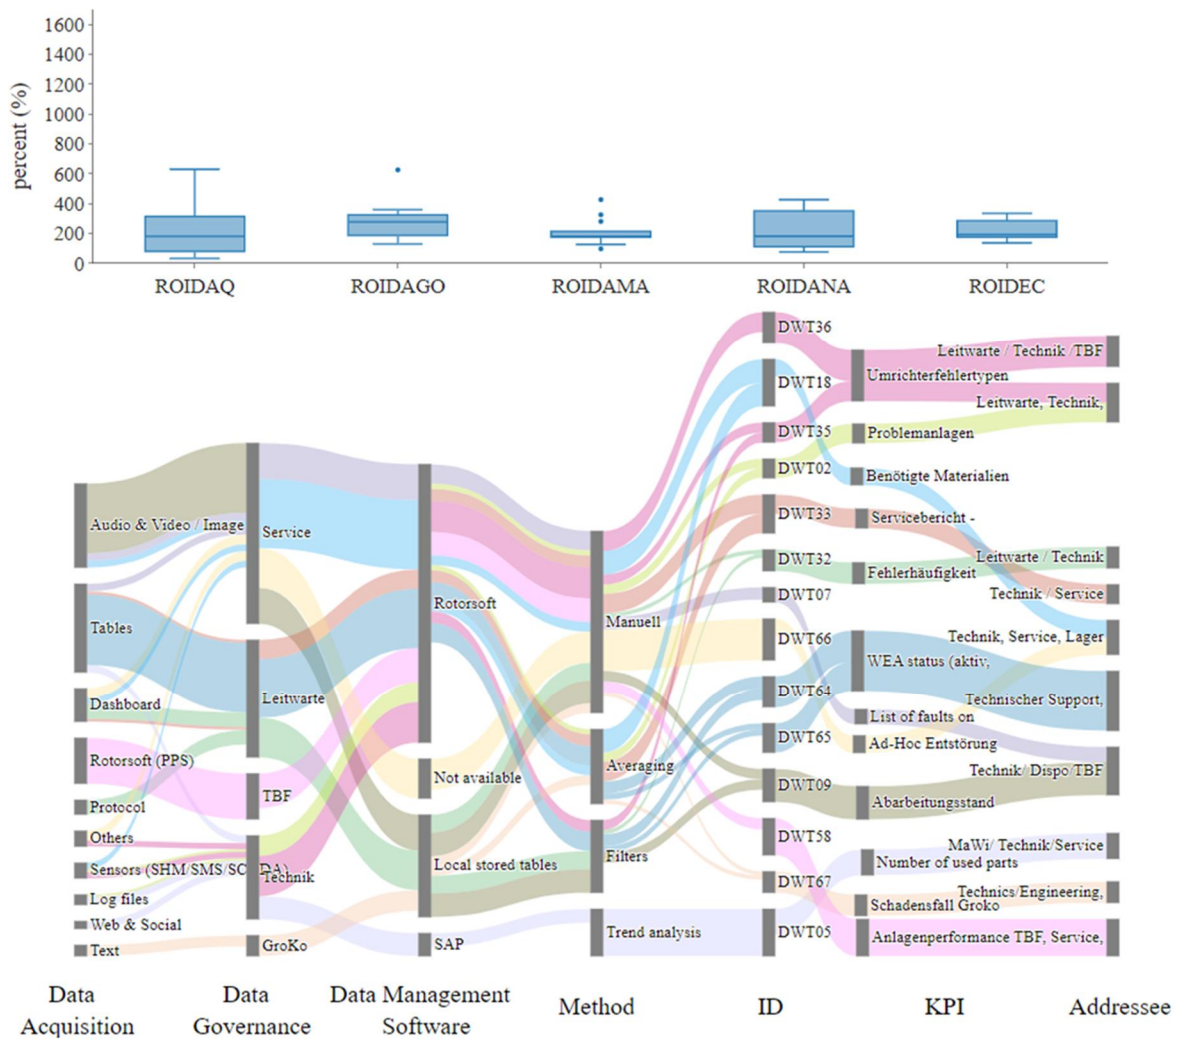


Abb. 6.15: Sankey-Diagramm Gesamtübersicht Deutsche Windtechnik

Die Gesamtübersicht des Sankey-Diagramms (siehe Abb. 6.15) für die Deutsche Windtechnik zeigt, dass vielschichtige Datenquellen (darunter ein großer Anteil Tabellen) in der Datenanalyse auf einen hohen Anteil an manuellen Auswertungen treffen. Hier stellen sich Fragen nach dem *Single Point of Truth* und der Möglichkeit, Datenanalysen zu automatisieren. Im ersten Schritt ist zu klären, ob die Daten tatsächlich dezentral in Silos vorliegen oder alle Daten zentral vorhanden sind und von dort in Tabellen und andere Systeme überführt werden. Im direkten Anschluss können Optimierungen im Bereich des Datenmanagements und der Data-Governance-Regeln durchgeführt werden. So kann gewährleistet werden, dass Daten zentral vorliegen und die Datenqualität durch Prozesse und Rollen, z. B. Data-Stewards, sichergestellt wird.

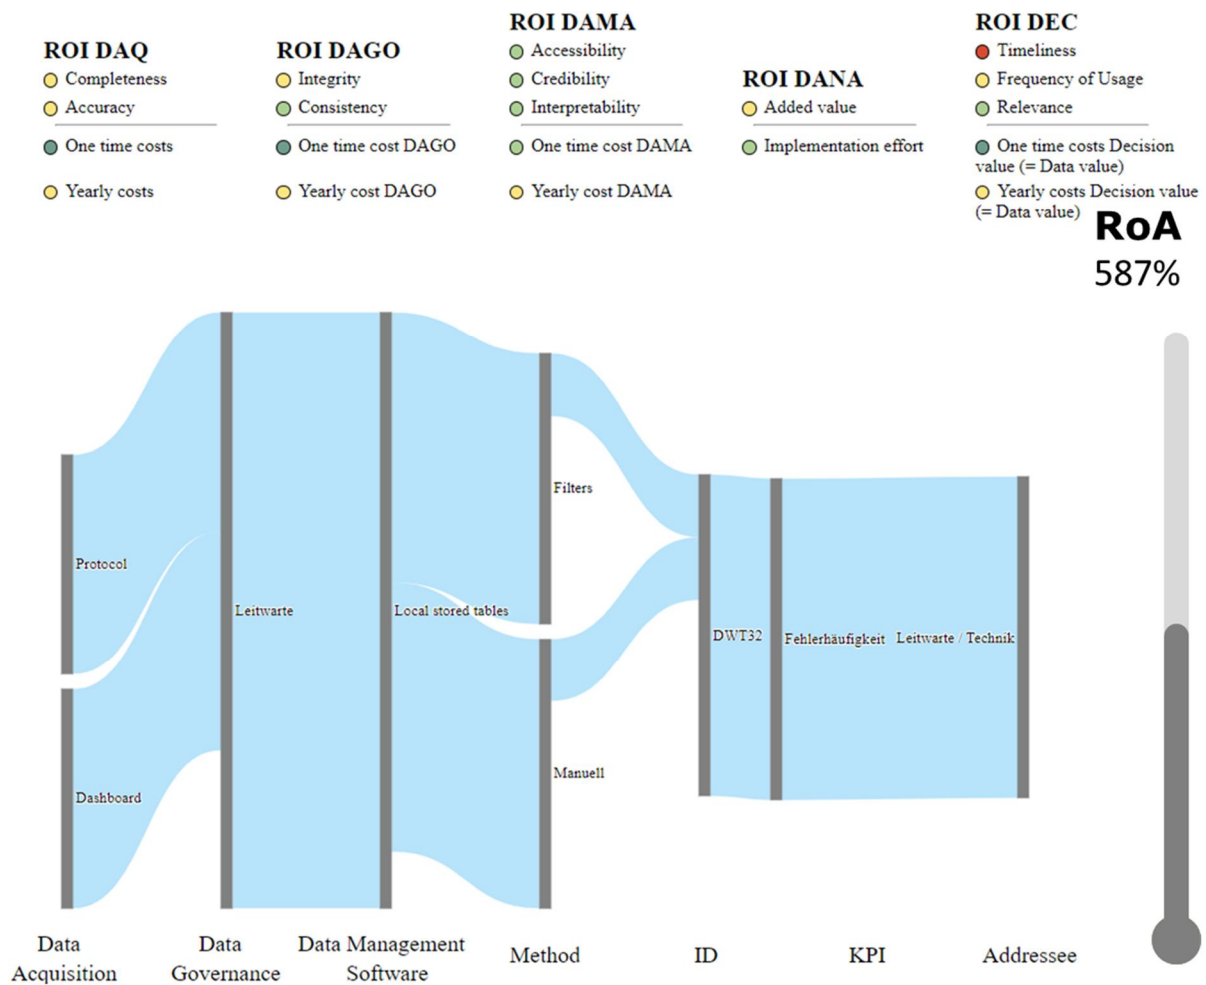


Abb. 6.16: Sankey-Diagramm Datenprodukt DWT32: *Ist der Fehler schon häufiger aufgetreten?*

Das Datenprodukt DWT32 (siehe Abb. 6.16) beantwortet die Frage, ob ein Fehler im Windpark oder in den Windenergieanlagen bereits häufiger aufgetreten ist. *Anwenderbericht:* Die Leitwarte oder der technische Support möchten wissen, welche Fehler wiederholt auftreten, um technische Verbesserungen und Einsätze angemessener zu planen. In der Betrachtung der Datenwertschöpfungskette stellt sich die Frage, ob die Datenqualität voll genutzt wird. Die Leitwarte ist der Data-Steward und

stellt sicher, dass die Informationen aus Protokollen und Dashboards ausgewertet und in lokal gespeicherten Tabellen dokumentiert werden. Durch Filtern und manuelle Auswertungen kann der technische Support die Daten auswerten und nutzen. Im Bereich des Datenmanagements sind lokal gespeicherte Tabellen kritisch zu betrachten, da so kein Single Point of Truth vorliegt. Metadaten können in diesem Fall über verschiedene Speicherorte variieren und eine weitere Verwendung der Daten erschweren. Der hohe manuelle Aufwand in der Datenanalyse führt zu der Frage, ob eine Optimierung durch eine Automatisierung der manuellen Tätigkeiten möglich wäre. So könnte die Basis für datengetriebene Entscheidungen verbessert werden.

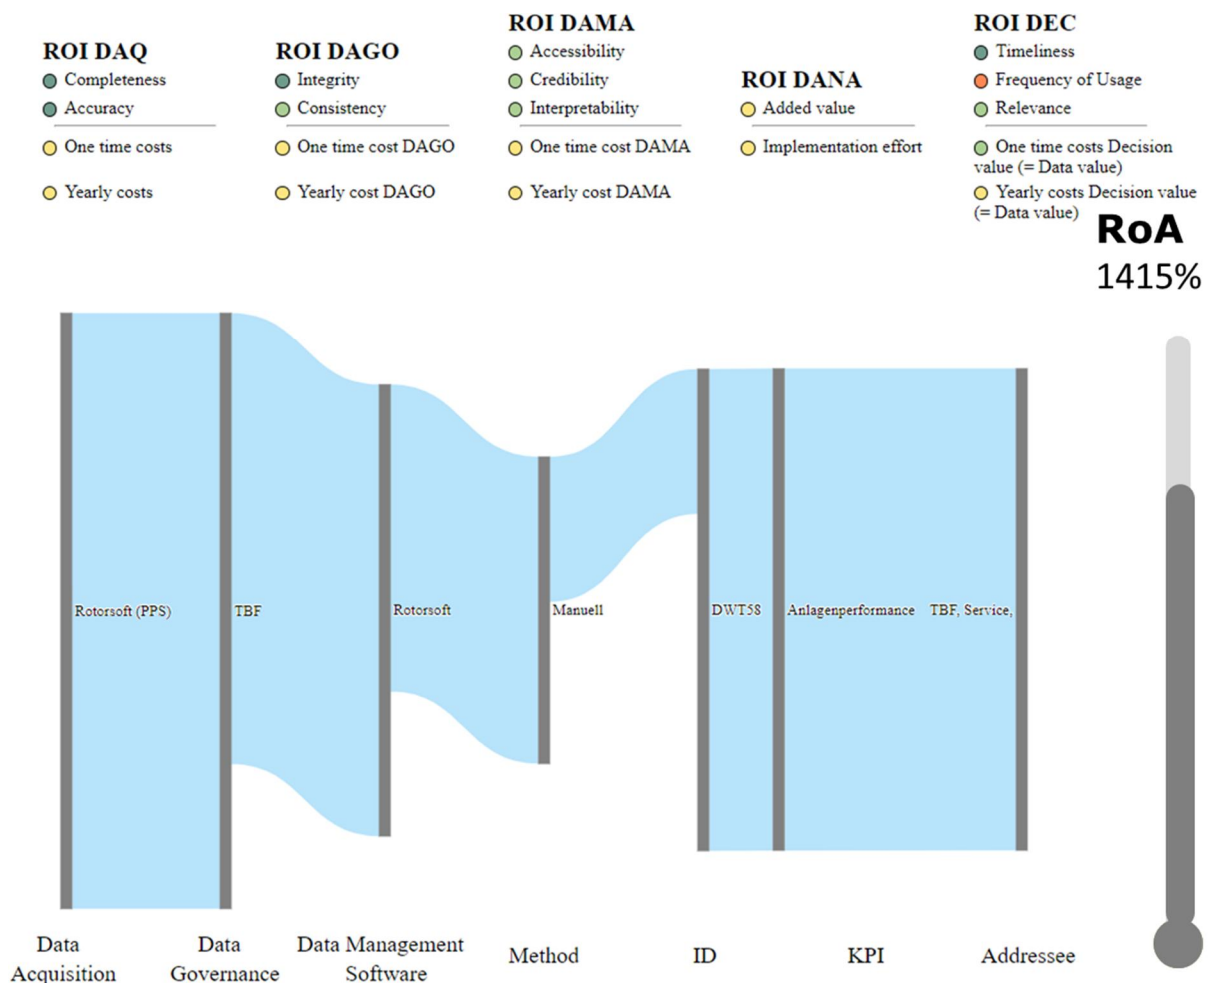


Abb. 6.17: Sankey-Diagramm Datenprodukt DWT58: *Performt die Windenergieanlage gemäß Nennleistungskurve?*

Das vorhandene Datenprodukt DWT58 (siehe Abb. 6.17) beantwortet die Frage, ob die Anlage gemäß Nennleistungskurve Strom produziert (unter vorheriger Berücksichtigung möglicher Abweichungen aufgrund von nächtlicher Schallreduzierung oder Anlagendrosselungen). *Anwenderbericht:* Die Leitwarte oder der technische Support möchten wissen, ob Abweichungen von der Nennleistungskurve existieren. So kann entschieden werden, welche korrigierenden Maßnahmen getroffen werden müssen. Diese Information wird für die monatliche Berichterstattung zur Vor-

bereitung auf Treffen oder Konferenzen mit Betreibenden oder zur Analyse der Anlagen-Performance seitens der technischen Betriebsführung benötigt. Als Software für die Analyse wird Excel verwendet, dafür werden 10-Minuten-Daten aus *ROTORsoft*.⁵² oder der Steuerung sowie die Auswertungsmöglichkeiten direkt in *ROTORsoft* genutzt; die Visualisierung erfolgt in Form eines Kennliniendiagramms (Wind- und Leistungswerte im 10-Minuten-Mittel). Die separate Auswertung in Form von Excel oder in Form des Monatsberichts wird seitens der technischen Betriebsführung an die Kund*innen der Deutschen Windtechnik geschickt. Die Monatsberichte werden in der Ordnerstruktur des Windparks abgelegt. Auswertungen der Leistungskurven sind alternativ jederzeit in *ROTORsoft* abrufbar. Bei der Auswertung der Datenwertschöpfungskette fallen verschiedene mögliche Optimierungen ins Auge. Zum einen kann ein hoher ROI bei den Datenquellen genutzt werden, die indes nur manuell weiterverarbeitet werden. Zum anderen könnte die Wertschöpfung erhöht werden, indem Daten den Anwendenden zeitnaher, etwa durch Automatisierung, zur Verfügung gestellt werden.

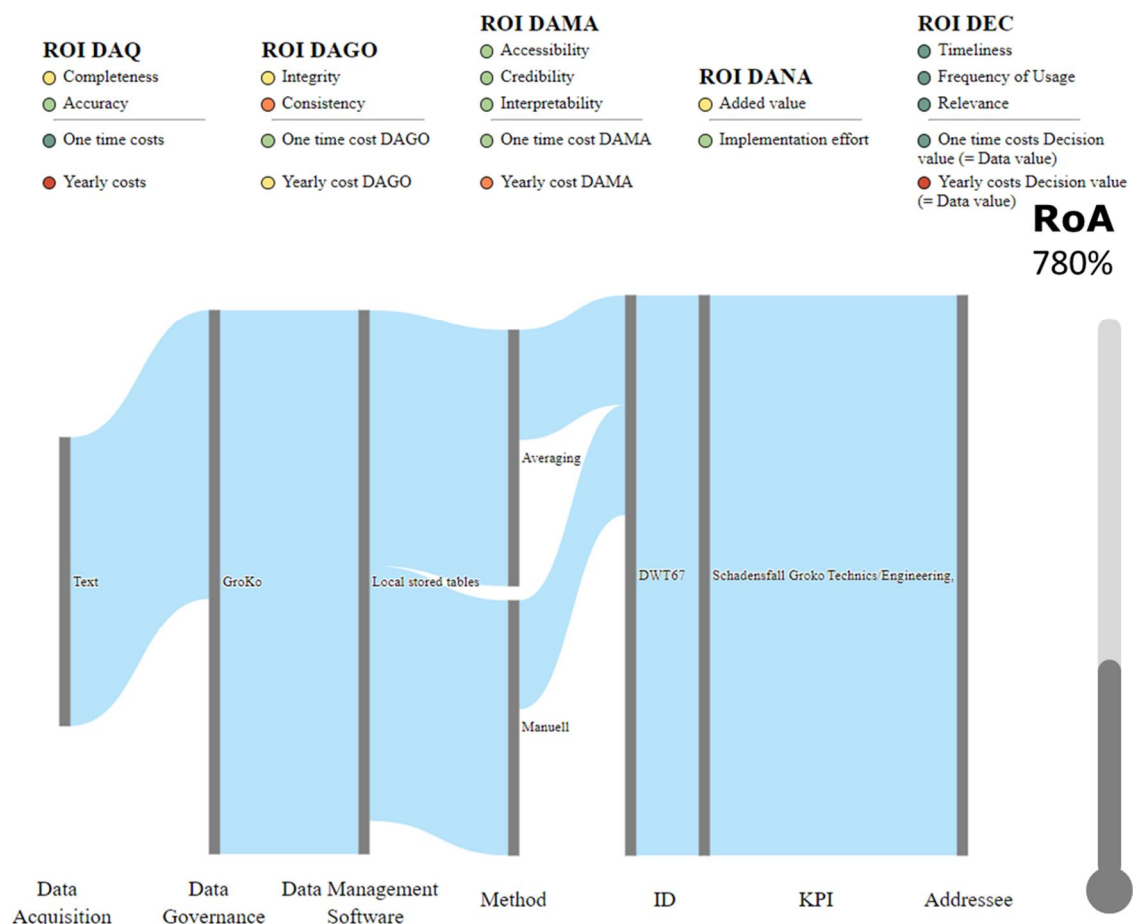


Abb. 6.18: Sankey-Diagramm Datenprodukt DWT67: Um welchen Schaden handelt es sich?

⁵² ROTORsoft ist eine auf Windenergie spezialisierte Betriebsführungs- und Überwachungs-Software.

Das Datenprodukt DWT67 (siehe Abb. 6.18) befasst sich mit der Frage, um welchen (Großkomponenten-)Schaden es sich handelt. *Anwenderbericht:* Die Arbeitsvorbereitung und die Arbeitsplanung möchten wissen, welcher Schaden vorliegt, um die Einsatzplanung vorzubereiten. Dafür muss bewertet werden, welches Gewicht das zu wechselnde Teil hat und ob ggf. ein Kran benötigt wird. Das Datenprodukt wird in Form von Excel-Listen als Report und E-Mail-Mitteilung versendet. Als Datenquelle wird Text genutzt, der von der Abteilung Großkomponente ausgewertet wird. Die Auswertungen werden in Form lokal gespeicherter Tabellen manuell oder durch Mittelung vorgenommen. Dies sorgt dafür, dass lediglich unpräzise Informationen vorliegen, da die Fehlermeldungen manuell geschehen. Das Ziel für die Deutsche Windtechnik ist eine verbesserte Einsatzplanung; hierbei müssten einerseits die Art der Datenerfassung und andererseits die Art der Datenanalyse optimiert werden. Speziell die Vollständigkeit der Daten und die Kosten der Datenakquise können verbessert werden. Auf der organisatorischen Seite könnte die Konsistenz der Fehlermeldungen optimiert werden.




Abb. 6.19: Sankey-Diagramm Datenprodukt DWT05: Welche Bauteile wurden überdurchschnittlich häufig verbraucht?

Das vorhandene Datenprodukt DWT05 (siehe Abb. 6.19) bezieht sich auf die Frage, welche Bauteile überdurchschnittlich häufig verbraucht wurden. *Anwenderbericht:* Die Materialwirtschaft, der tech-

nische Support und die Arbeitsvorbereitung möchten wissen, welche Bauteile stärker ausgelegt werden müssen und wo erhöhter Verschleiß oder Handlungsbedarf besteht. Der technische Support stellt die Datenqualität für dieses Datenprodukt sicher; es wird als Tabelle der Materialhistorie je Anlage aus der Wartungssoftware *L-Mobile*⁵³ ausgegeben. Eine Analyse der Datenwertschöpfungskette ergibt, dass Datenmanagement und Data-Governance verbessert werden sollten. So stehen die Input-Daten in verschiedenen Logfiles, Tabellen oder internen Web- und Social-Media-Kanälen. Um eine bessere Datenqualität zu gewährleisten, bietet es sich an, einen Single Point of Truth zu etablieren. Hinsichtlich der Datenanalyse ist zu fragen, ob die Datenqualität mit einer Trendanalyse vollständig ausgeschöpft werden kann. Ebenfalls ist zu bewerten, ob die Methode zum Entscheidungswert passt. Für die Entscheidung ist von der Deutschen Windtechnik die Informationsverteilung zu den Anwendenden zu prüfen.

Aufgrund der vielen verschiedenen Datenquellen bei der Deutschen Windtechnik empfiehlt es sich, diese enger miteinander zu verknüpfen (z. B. durch Bündelung der Daten in einem Data-Warehouse oder die Einführung eines Datenkatalogs). Die Schaffung einer universellen Sprache, die durch Mittel wie eine Taxonomie oder eine Ontologie erreicht werden könnte, birgt das Potenzial, die Nutzung einer Vielzahl von Protokollen von Windkraftanlagenherstellern und -typen zu verbessern. Zur Bewertung des Datenmanagements können verschiedene Maße der Datenqualität herangezogen werden. Anhand dieser Größen lässt sich ermitteln, welche Teile der Datenqualität verbessert werden können, um das Datenmanagement zu optimieren. Neben der Datenqualität ist es ebenfalls von Bedeutung, Datenstrukturen und Ontologien zu verstehen (vgl. Seiner 2014, S. 65). Ohne *Wörterbücher*, die alle Datenbanken verwenden, können sie nicht adäquat miteinander kommunizieren. Durch diese Datenstruktur steigt das Risiko, dass in Organisationen mehrere Versionen derselben Daten vorliegen, die von verschiedenen Stakeholdern je nach Anwendungsfall angepasst werden, wodurch Datensilos⁵⁴ entstehen. Folglich erschweren gewachsene Datenstrukturen wie bei der Deutschen Windtechnik die Existenz eines Single Point of Truth, der als einzig wahre Datenquelle dient.

Da der Großteil der Datenanalyse bei der Deutschen Windtechnik derzeit manuell durchgeführt wird, besteht ein erheblicher Automatisierungsbedarf der Datenanalysen, -aufbereitung oder -pflege. Verbesserungen könnten auch auf organisatorischer Ebene erreicht werden, z. B. durch festgelegte Rollen und Data-Governance.

⁵³ L-Mobile ist ein deutscher Software-Anbieter, der Arbeitsabläufe unter anderem innerhalb der Betriebsführung und Instandhaltung digitalisiert.

⁵⁴ Datensilos bezeichnen vorhandene eigenständige Daten oder Kopien von Daten, die nicht mit der Ursprungsquelle oder einem zentralen Datenspeicher verknüpft sind.

7 Schlussbetrachtung

Daten repräsentieren einen bedeutenden Rohstoff für das nächste *Wirtschaftswunder* (vgl. Kordon 2020, S. 40 f.). Ähnlich wie beim Erdöl müssen Rohdaten zunächst verarbeitet werden, damit sich ihr Wert effizient ausschöpfen lässt. Das Ziel der Datenwertschöpfungskette besteht darin, den aus Daten abgeleiteten Wert für Organisationen zu verbessern. Um dies zu erreichen, müssen alle Komponenten einer Datenwertschöpfungskette berücksichtigt werden, einschließlich der Datenquelle, der Data-Governance, des Datenmanagements, der Datenverarbeitung oder -erfassung, der Datenanalyse und der Entscheidungsfindung.

Aufgrund der für jede Organisation einzigartigen Datenwertschöpfungskette musste das Modell erweiterbar und generalisierbar sein. Die entwickelte Datenwertschöpfungsketten-Ontologie und das Evaluationsmodell sind modular anpassbar. Je nach Anwendungsfall bietet es sich an, die Säulen und Elemente bedarfsabhängig zu verwenden und je nach den Besonderheiten von Datenwertschöpfungsketten anzupassen. Dies ermöglicht es, die Anforderungen verschiedener Anwendungen und Forschungsfelder zu berücksichtigen. Auf diese Weise kann eine bestmögliche Übertragbarkeit auf andere Anwendungsgebiete erreicht werden.

7.1 Zusammenfassung

Anhand einer Literaturrecherche wurde untersucht, wie der Begriff der Datenwertschöpfungskette definiert wird. Im Rahmen der vorliegenden Arbeit wurden verschiedene Online-Datenbanken (IEEE und IET, ACM Digital Library, Springer Link, Science Direct, AISeL, Wiley Online Library) nach dem Begriff *data value chain* durchsucht. Im Ergebnis wurden 27 Einzelquellen identifiziert, von denen 21 frei verfügbar waren und in die Auswertung eingeflossen sind. Die relevantesten Datenwertschöpfungsketten-Modelle (vgl. Cavanillas et al. 2016, S. 32; Miller und Mork 2013, S. 3) wurden mit dem BMC und einem eigenen vereinfachten Modell verglichen. Da diese Modelle sich stark ähneln, wurden sie innerhalb dieser Arbeit zu einem Datenwertschöpfungsmodell verallgemeinert (vgl. Bendlin et al. 2024).

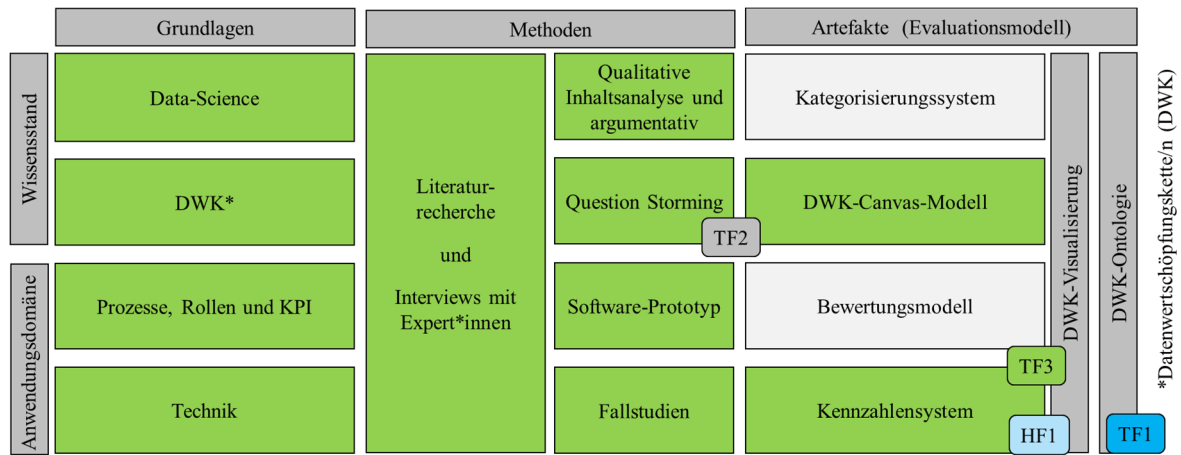
Ein weiterer eingehend untersuchter artverwandter Forschungsbereich sind datengetriebene Entscheidungsprozesse (vgl. Foroughi und Luksch 2018, S. 10). Unter diesen Modellen hat sich CRISP-DM mit einer Betonung der Datenanalytik als Quasistandard etabliert. Gleichwohl steht die Wertschöpfung für die Anwendungsdomäne in diesem Prozessmodell im Hintergrund. Diese Lücke können Canvas-Modelle schließen, die vom ursprünglichen BMC (vgl. Osterwalder 2004, S. 44) inspiriert sind. Für Data-Science und verwandte Anwendungen konnten verschiedene Canvas-Modelle durch eine Literaturrecherche identifiziert werden. Sie verfolgen unterschiedliche Schwerpunkte, die vom Prozess des Datenmanagements über die Datenanalyse bis hin zur Anwendungs-

domäne reichen können. Die Literaturrecherche identifizierte 21 verschiedene Canvas-Modelle für die Wertschöpfung aus Daten (vgl. Bendlin et al. 2024, S. 83). Angesichts der Vielfalt der Modelle ist eine allgemeine Lösung unwahrscheinlich. Dies zeigt sich an den zahlreichen Modellen und Methoden, die darauf abzielen, Datenanalysen im Kontext der Wertschöpfung einer Organisation zu betrachten. Da diese Datenwertschöpfungsketten unterschiedlich ausgeprägt sind, kann davon ausgegangen werden, dass aktuelle Modelle nicht universell einsetzbar sind. Aus diesem Grund ist das entwickelte Modell nicht statisch, sondern modular erweiterbar, um die Anwendungsdomäne bzw. den Forschungsrahmen individuell abbilden zu können.

7.2 Limitationen und weiterer Forschungsbedarf

Die bewusste Reflexion über die Limitationen und Ergebnisse von Forschungsarbeiten erlaubt die Identifikation weiteren Forschungsbedarfs. Diese Forschungslücken ermöglichen es somit, bestehende oder entwickelte Modelle zu verbessern und weiterzuentwickeln. Zusätzlich gestattet der transparente Umgang mit Limitationen und Ergebnissen eine bessere Einordnung in den bestehenden Forschungsrahmen. Gleichzeitig können diese Ergebnisse einen Einfluss auf die Anwendungsdomäne und die Interpretation bzw. Nutzbarkeit der Ergebnisse haben.

Im Zentrum der vorliegenden Arbeit steht die Entwicklung eines Evaluationsmodells für Datenwertschöpfungsketten. Dieses Ziel wurde durch Literaturrecherchen und Aktionsforschung erreicht. Durch einen iterativen Ansatz von Literaturrecherchen sowie Interviews mit Expert*innen wurde das Modell immer weiter verfeinert und geschärft. Dabei wurde ein hoher Fokus auf die Übertragbarkeit, Einfachheit und Verständlichkeit des Modells gelegt. Durch den modularen Aufbau der Datenwertschöpfungskette können einzelne Bestandteile – je nach Forschungsschwerpunkt oder Optimierungsfokus – genauer untersucht werden. Gleichzeitig ist die Möglichkeit vorhanden, Datenprodukte zu priorisieren, damit diese ausführlicher untersuchbar sind. Um die Datenwertschöpfungskette durch ein Evaluationsmodell bewertbar zu machen, wurden verschiedene Forschungsfragen abgeleitet. Abbildung 7.1 liefert eine Übersicht über die Forschungsfragen und Artefakte; verbesserungswürdige Artefakte sind hierbei zur besseren Unterscheidung grau gehalten.



HF: Wie kann eine Datenwertschöpfungskette evaluiert, visualisiert und analysiert werden?

TF1: Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?

TF2: Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?

TF3: Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?

Abb. 7.1: Beantwortung der Forschungsfragen

Eine bedeutende Herausforderung bestand darin, eine auf die Forschungsfrage bezogene Balance aus Einfachheit und Komplexität des Modells zu finden. Einerseits galt es, eine Struktur und Visualisierung zu ermitteln, durch die das Evaluationsmodell von den Zielgruppen der Anwendenden und Data-Scientist*innen schnell verstanden werden konnte. Andererseits musste das Abstraktionsniveau anpassbar sein, um verschiedene Schwerpunkte zu setzen. Der modulare Aufbau des Evaluationsmodells hilft dabei, Evaluationen ziel- und forschungsfragengerecht zu definieren. Die Aktionsforschung erlaubte es, das Modell iterativ durch Rückmeldungen der Forschungs- und Industriepartner zu verbessern. Im Weiteren werden die Limitationen der Forschungsergebnisse dieser Arbeit entlang der Forschungsfragen diskutiert, um daraus im anschließenden Kapitel theoretische und praktische Implikationen abzuleiten.

TF1: Wie muss eine Datenwertschöpfungskette aufgebaut sein, um Entscheidungsfindungen datengetriebener zu gestalten?

Grundbegriffe wie Datenprodukte oder Datenwertschöpfungskette wurden innerhalb des Forschungsprojekts *WiSA Big Data* frühzeitig eingeführt. Daraus resultierte eine hohe Akzeptanz der Begriffe, die sich in der Übernahme in den Sprachgebrauch der Forschungs- und Industriepartnern zeigte. Grundgedanken des Evaluationsmodells wie der ROI oder der RoA als Kernstücke des Kennzahlensystems und das Datenwertschöpfungsketten-Canvas als Schnittstelle zu den Anwendenden wurden ebenfalls einfach gehalten, um die Verständlichkeit und Akzeptanz des Evaluationsmodells zu erhöhen.

Zur Erstellung des Evaluationsmodells wurde eine Literaturrecherche durchgeführt. Da jede der verwendeten Online-Literaturdatenbanken eine eigene Suchmaschine aufwies, konnten die Suchalgorithmen nicht universell eingesetzt werden. Dadurch kann die Qualität von Suchergebnissen einer Literaturrecherche kompromittiert werden. Für diese Arbeit wurden daher individuelle Suchalgorithmen genutzt. Dass aus der Recherche eine gute Übersicht folgte, offenbart sich im Vergleich mit existierenden Übersichtsstudien (Fruhirth et al. 2020, S. 522; Neifer et al. 2021, S. 5401), die zusammen 14 Canvas-Modelle identifizierten. Im Rahmen der für diese Arbeit durchgeführten Literaturrecherche konnten sieben weitere Modelle identifiziert werden (vgl. Bendlin et al. 2024, S. 83). Die Ergebnisse der Recherche wurden herangezogen, um für die Untersuchung von Datenwertschöpfungsketten das ursprüngliche BMC (vgl. Osterwalder 2004, S. 44) anzupassen und um ein Kennzahlensystem zu erweitern. Der Grundgedanke des ROI – Return on Information – ist im Kern einfach nachvollziehbar. Er fügt den existierenden Definitionen in Bezug auf den Begriff der Datenwertschöpfungskette und hinsichtlich der Canvas-Modelle eine objektive Kennzahl hinzu. Da es sich dabei um einen neuartigen Ansatz handelt, konnte lediglich auf vereinzelte Vorarbeiten wie den BVI oder Kennzahlen zur Datenqualität zugegriffen werden. Mithin war es notwendig, bei der Analyse der Datenwertschöpfungskette Systemgrenzen zu definieren. Aufgrund der Komplexität des entwickelten Evaluationsmodells war es im Rahmen des Forschungsprojekts *WiSA Big Data* nicht möglich, alle angrenzenden Faktoren und Bedingungen darzustellen. Stattdessen wurden diese Themen als gegebene oder untergeordnete Faktoren angenommen. So ist es beispielsweise gängige Praxis, sich an die Richtlinien einer Organisation zu halten, z. B. in Bezug auf Datenethik und Datensicherheit. Bei großen Projekten mit komplizierten Vereinbarungen mit Stakeholdern ist Datensicherheit indes ein Hindernis für die gemeinsame Nutzung von Daten. Im aktuellen Evaluationsmodell wurden diese Faktoren vereinfachend der Data-Governance und dem Datenmanagement zugeordnet, könnten aber in zukünftigen Modellerweiterungen entsprechend berücksichtigt werden.

TF2: Welche relevanten Fragestellungen, d. h. Datenprodukte in der Anwendungsdomäne, könnten mithilfe von Datenanalysen beantwortet werden?

Da die Identifikation relevanter Datenprodukte sowie die Bewertung der Datenwertschöpfungskette durch Expert*innen hochgradig subjektiv ist, erscheint ein Einfluss durch die Auswahl der Evaluationsteilnehmenden wahrscheinlich. Zwar lag die Auswahl der Evaluationsteilnehmenden bei den Industriepartnern, es sollten jedoch stets erfahrene Anwendende aus den Organisationseinheiten ausgewählt werden, die mit den Ergebnissen der Datenanalysen arbeiten oder arbeiten könnten. Die Auswahlkriterien zielten darauf ab, eine breite Menge an Datenprodukten zu identifizieren. Um den Herausforderungen der Subjektivität zu begegnen, wurden dieselben Verfahren und Evaluationsbeschreibungen für alle Industriepartner verwendet. Gleichzeitig wurden verschiedene Sichtweisen

der Fachbereiche kombiniert, um ein möglichst homogenes Ergebnis zu erhalten. Die neutrale Priorisierung der Datenprodukte durch die Forschungs- und Industriepartner sowie die Einführung objektiver Kennzahlen im Kennzahlensystem beugten einer einseitig beeinflussten Verzerrung der Ergebnisse zusätzlich vor. Zukünftige Forschung könnte untersuchen, welchen Einfluss diese Auswahlkriterien auf die Ergebnisse der Untersuchung einer Datenwertschöpfungskette haben.

QuestionStorming erwies sich als geeignete Methode, um eine Vielzahl verschiedener Datenprodukte zu identifizieren. Mit den Industriepartnern wurden mehr als 50 individuelle Interviews mit Expert*innen anhand von QuestionStorming (vgl. Dyer et al. 2011, S. 70) durchgeführt und es konnten 151 Datenprodukte aufgezeichnet werden. Die Themenvielfalt der erhobenen Datenprodukte wurde von den Expert*innen als repräsentativ bewertet. Dabei trat zutage, dass es – um den adäquaten Fokus in der Evaluation zu setzen – notwendig war, die Datenprodukte zu priorisieren sowie zu kategorisieren. Die Basis für die Priorisierung durch eine Nutzwertanalyse wurde mit den Forschungs- und Industriepartnern festgelegt. Da sowohl die Anwendungsdomäne durch die Industriepartner als auch die Data-Science durch die Forschungspartner berücksichtigt wurden, konnte eine objektivere Bewertung ermöglicht werden. Neben dem Erkennen und Priorisieren von Datenprodukten in der Wertschöpfungskette einer Organisation ist es wesentlich, Kategorien für die dringendsten Herausforderungen bei der Wertschöpfung aus Daten zu identifizieren. Ein Hauptverbesserungspotenzial des innerhalb der vorliegenden Arbeit entwickelten Evaluationsmodells betrifft das Kategorisierungssystem. Für die vorliegende Arbeit wurde nach einem Rahmenwerk gesucht, das die Anwendungsdomäne möglichst objektiv repräsentiert. Die gewählte Kategorisierung der EN 15341:2019 *Maintenance Key Performance Indicators* (vgl. CEN 2019, S. 10 ff.) erfüllt jedoch nicht das Kriterium der einfachen Verständlichkeit mit acht Haupt- und 32 Unterkategorien, die transparent definiert und von allen Evaluationsteilnehmenden verstanden werden müssen. Dabei zeigte sich, dass einige der Kategorien nicht eindeutig abgegrenzt waren. Um dieser Herausforderung zu begegnen, wurde eine Definition der Kategorien erarbeitet und mit den Industrieteilnehmenden geteilt. Gleichzeitig wurden die Unterkategorien lediglich im Zusammenhang mit den Hauptkategorien evaluiert. Neben den vorhandenen Haupt- und Unterkategorien der EN 15341:2019 (vgl. CEN 2019, S. 10 ff.) könnten zukünftig auch organisationsinterne bzw. -individuelle Kategorien festgelegt werden. Für die bessere Vergleichbarkeit mit den anderen Industrieteilnehmenden innerhalb des Forschungsprojekts *WiSA Big Data* wurde im Rahmen der vorliegenden Evaluation auf individuelle Kategorien verzichtet. Gleichwohl offenbarte sich im Evaluationsverlauf, dass nur ein Bruchteil der Kategorien im Forschungsprojekt *WiSA Big Data* und bei den untersuchten Datenprodukten Verwendung fand. Der Dialog mit Forschungs- und Industriepartnern ermöglichte eine iterative Verbesserung des Evaluationsmodells, des Kategorisierungssystems und der Visualisierung.

TF3: Welche Teile der Datenwertschöpfungskette könnten in Bezug auf Kosten/Nutzen optimiert werden?

Da die Nutzwertanalyse auch zur Bewertung des ROI für die Datenanalyse (ROI_{DANA}) verwendet wurde, stellen die Bewertungen der anderen Bestandteile der Datenwertschöpfungskette eine Alternative zur Priorisierung von Datenprodukten dar. So lassen sich Datenprodukte mit hohem oder niedrigem ROI bezogen auf die Bestandteile der Datenwertschöpfungskette identifizieren und so z. B. basierend auf dem ROI_{DEC} priorisieren. Laut den Teilnehmenden der Interviews ist das Konzept des ROI zwar klar verständlich, die Anzahl der zur Berechnung des ROI herangezogenen Faktoren (bis zu fünf) erschien den Evaluationsteilnehmenden indes zu hoch. In Verbindung mit der Skalierung auf bis zu fünf Einheiten wird das Modell kompliziert. Eine einfache Ampelauswahl mit nur drei Optionen pro Bestandteil der Datenwertschöpfungskette würde die Bewertungsmethodik vereinfachen. Diese Vereinfachung steht allerdings der Genauigkeit der Ergebnisse entgegen.

Im aktuellen Evaluationsmodell sind Ambitionslevel ein vernachlässigbarer Faktor bei der Gewichtung und Priorisierung der Datenprodukte, allerdings könnte das Gewicht des RoA erhöht werden, um mehr Aufmerksamkeit auf Kategorien mit höherem Ambitionslevel zu lenken. Hierbei ist zu erwähnen, dass die Ambitionslevel innerhalb einer Organisation abweichen können und daher idealerweise auch auf verschiedenen Organisationsebenen untersucht werden sollten. So hat die Untersuchung bei der Deutschen Windtechnik ergeben, dass einzelne Organisationseinheiten bei der Bewertung der Ambitionslevel abweichende Ergebnisse haben können (siehe etwa Anhang H). Durch die Vereinheitlichung abweichender Ergebnisse ließe sich ein für die Organisation allgemeingültigeres Bild ableiten oder durch mögliche Abweichungen der Ambitionslevel könnten Unstimmigkeiten innerhalb einer Organisation identifiziert werden.

Da verschiedene Skalen verwendet wurden (die Nutzwertanalyse oder eine schriftliche Skala mit Beschreibungen für die Evaluationsteilnehmenden sowie numerische Werte in Euro für die Bewertung), mussten die Evaluationsergebnisse umgerechnet werden. Ein vereinfachtes Evaluationsmodell würde eine schnellere Auswertung der Ergebnisse ermöglichen. Durch die Fülle der Kennzahlen wird das System unübersichtlich. Auch der ROI könnte reduziert werden, um den Evaluationsablauf weiter zu vereinfachen.

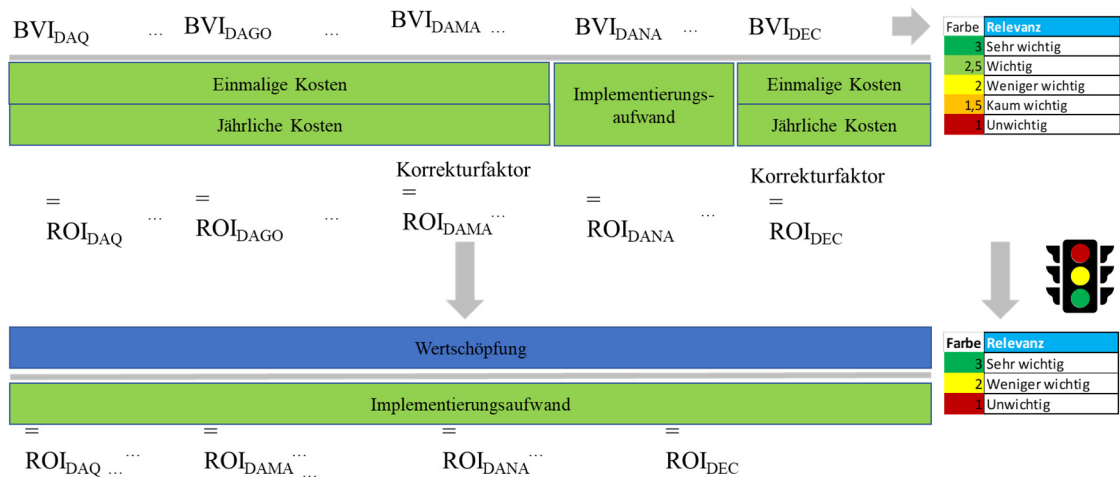


Abb. 7.2: Beispielhafte zukünftige Vereinfachung des Bewertungsmodells und der Skalierung

Beispielsweise könnte jeder Bestandteil der Datenwertschöpfungskette nur durch zwei Kennzahlen (für die Wertschöpfung und für den Implementierungsaufwand) bestimmt werden. Infolgedessen müssten in einem vereinfachten Evaluationsmodell der Datenwertschöpfungskette nur noch zehn Variablen bewertet werden – im Vergleich zu 28 Variablen im aktuellen Modell. Außerdem könnte die Anzahl der Bestandteile der Datenwertschöpfungskette (DAQ, DAGO, DAMA, DANA, DEC) reduziert werden (siehe Abb. 7.2).

HF: Wie kann eine Datenwertschöpfungskette evaluiert, visualisiert und analysiert werden?

Um die Zusammenhänge des Evaluationsmodells verständlich zu veranschaulichen, wurde eine Datenwertschöpfungsketten-Ontologie erstellt. Die Komplexität der Ontologie der Datenwertschöpfungskette könnte ebenfalls vereinfacht werden, um eine schnellere Analyse zu ermöglichen. Ihre Ähnlichkeit mit dem bewährten BMC-Modell macht sie leicht verständlich, aber auch dieses Modell ist mit neun Säulen sehr ausführlich. Müssten die Evaluationsteilnehmenden weniger Fragen beantworten, könnte die Befragung für diese Fragen tiefgründiger gestaltet werden. Hier wurde von den Industriepartnern darauf hingewiesen, dass ein Glossar dabei helfen würde, das Evaluationsmodell besser zu verstehen. Um darauf zu reagieren, wurde die Datenwertschöpfungsketten-Ontologie mit der Anwenderschnittstelle des Datenwertschöpfungsketten-Canvas entwickelt. Das Datenwertschöpfungsketten-Canvas als abgewandelte Version des BMC schien den Industriepartnern gut geeignet, um Anforderungen der Anwendungsdomäne und der Data-Science aufzunehmen. Das Datenwertschöpfungsketten-Canvas hilft dabei, Datenprodukte zu konsolidieren, klar zu definieren und zu priorisieren. Es umfasst Informationen wie die Häufigkeit der Nutzung von Datenprodukten, interne und externe Schnittstellen sowie eine klare Definition des Anwenderberichts. Bei der Übertragbarkeit der Ergebnisse ist zu beachten, dass sich die Dokumentation der Ontologie an der Definition des BMC-Canvas (vgl. Osterwalder 2004, S. 44) orientiert. Das Evaluationsmodell hätte auch in Form einer etablierten Modellierungssprache, etwa der *Unified Modelling Language*, doku-

mentiert werden können. Da innerhalb dieser Arbeit der Proof of Concept und die Entwicklung des Evaluationsmodells im Vordergrund standen, wurde darauf verzichtet.

Zur Visualisierung der Datenwertschöpfungskette wurde ein Sunburst in Verbindung mit einem Sankey-Diagramm gewählt. Das Sunburst stellt Ambitionslevel für strategische Organisationsziele anhand vordefinierter Kategorien dar (siehe Anhang F–H). So kann durch die simultane Visualisierung der Evaluationsergebnisse direktes Feedback durch Evaluationsteilnehmende gegeben werden. Auch können verschiedene Bewertungen von Kategorien direkt miteinander verglichen und bei Bedarf angepasst werden. Die gewählte Methode zur Analyse der Ambitionslevel zeigte in der vorliegenden Evaluation eine hohe Akzeptanz bei den Evaluationsteilnehmenden. Die Visualisierung der Datenwertschöpfungskette über ein Sankey-Diagramm erleichtert es den Evaluationsteilnehmenden, die Ergebnisse zu verstehen und folglich Zusammenhänge und individuelle Besonderheiten der Datenwertschöpfungskette schnell zu erfassen. Werden nur wenige Datenprodukte angezeigt, ist die Sunburst- oder die Sankey-Visualisierung laut den Evaluationsteilnehmenden ansprechend und verständlich. Werden indes viele Datenprodukte verglichen, verliert das Modell an Klarheit. Um dieser Herausforderung zu begegnen, wurden verschiedene Filtermöglichkeiten und Ansichten implementiert. Eine Gesamtübersicht enthält alle Datenprodukte innerhalb einer Organisation. Diese Ansicht beinhaltet ein Whisker-Diagramm, um die verschiedenen ROI innerhalb der Datenwertschöpfungskette zu vergleichen. In einer zukünftigen Entwicklung könnten hier auch einzelne Datenprodukte eingeblendet werden, um sie im Vergleich zur gesamten Datenwertschöpfungskette darzustellen. Weitere Ansichten können durch zusätzliche Filter realisiert werden. Für z. B. einen detaillierten Einblick in die Evaluationsergebnisse können alle manuell analysierten Datenprodukte angezeigt und gemeinsam verglichen werden. In einer weiteren Detailansicht können Datenprodukte einzeln veranschaulicht werden. In dieser Ansicht stellt eine Ampel die Optimierungsprioritäten innerhalb der Datenwertschöpfungskette dar.

Die gewählte Umsetzung in einem Software-Prototyp durch Python sorgte für zusätzliche Limitierungen innerhalb der Visualisierung. So wurde das ausgegebene Sankey-Diagramm nicht automatisch auf Lesbarkeit optimiert. Dadurch wird die letzte Spalte des Sankey-Diagramms als Standard rechtsbündig angezeigt, während die restlichen Beschriftungen linksbündig angeordnet sind. Es ist möglich, diese letzte Spalte durch manuelles Verschieben ebenfalls linksbündig anzuordnen, allerdings kann es dabei vorkommen, dass eine einzelne Zeile rechts zentriert bleibt. Im Weiteren wird die Übersichtlichkeit durch das vorgegebene Layout erschwert, etwa durch das Fehlen eines Zeilenumbruchs im Sankey-Format bei außergewöhnlich langen Absätzen. Die Ströme des Sankey-Diagramms können sich zum Teil durch das Standard-Layout überlagern, was die Lesbarkeit zusätzlich einschränkt. Da das Sankey-Diagramm mit zunehmender Anzahl der Ströme komplexer wird, wurde eine Einfärbung des Sankey-Diagramms auf der Grundlage von Filtern eingeführt. In

der Einzelansicht der Datenprodukte sorgen Ampeln für eine schnelle Übersicht der einzelnen Optimierungsmöglichkeiten je Datenprodukt.

7.3 Theoretische und praktische Implikationen

Um die theoretischen und praktischen Implikationen aus den vorangegangenen Limitationen abzuleiten, werden zu Beginn die relevantesten Kernherausforderungen wiederholt:

- Der Einfluss von Subjektivität durch Evaluationsteilnehmende.
- Eine Balance zwischen Einfachheit und Komplexität des Evaluationsmodells, des Kategorisierungs- und Kennzahlensystems.
- Die Vielfalt der erhobenen Datenprodukte.
- Die Visualisierung der Ergebnisse.

Die Subjektivität der Einschätzung von Expert*innen ist eine Herausforderung, aus der sich theoretische und praktische Implikationen ergeben. So können menschliche Fehleinschätzungen eine Rolle bei den Evaluationsergebnissen spielen. Durch eine klare Beschreibung des Kategorisierungssystems, des Evaluationsmodells sowie durch objektive Bewertungskriterien mittels des Kennzahlensystems kann dieser Subjektivität begegnet werden. Eine Nutzwertanalyse wurde verwendet, um zu bestimmen, welche Datenprodukte am relevantesten sind und welche Wertschöpfung welchem Implementierungsaufwand in der Datenanalyse entspricht. Gleichwohl ist die Nutzwertanalyse zeitaufwendig und anfällig für menschliche Fehler, was indessen auch den Dialog und eine kritische Auseinandersetzung über die Richtigkeit des Vorgehens und die Bewertung fördern kann.

Im Gegensatz zur traditionellen Nutzwertanalyse verwenden Outranking-Methoden paarweise Vergleiche zur Ableitung von Präferenzwerten, um unterschiedliche Präferenzwerte und Wechselwirkungen zwischen Faktoren zu identifizieren (vgl. Geldermann und Lerche 2014, S. 13). Zukünftige Forschung könnte die Anwendung von Outranking-Methoden mit klassischen Nutzwertanalysen für die Bewertung einer Datenwertschöpfungskette vergleichen, um mögliche Mehrnutzen zu identifizieren. Bezogen auf die vorliegende Arbeit wurde die Nutzwertanalyse als besser geeignete Methode zur Beantwortung der Forschungsfragen bewertet, da das Ziel der Vergleich verschiedener Datenprodukte war. Eine zusätzliche Bewertung der Kriterien war hingegen nicht erforderlich. Zusätzlich konnte ein Vergleich mit alternativen Methoden zur Nutzwertanalyse für die Priorisierung im Rahmen des Forschungsprojekts nicht abgebildet werden.

Zur Balance zwischen Einfachheit und Komplexität muss zunächst verstanden werden, dass existierende Definitionen der Datenwertschöpfungskette (vgl. Cavanillas et al. 2016, S. 32; Miller und Mork 2013, S. 3) versuchen, die Datenwertschöpfungskette als Prozess analog zu datengetriebenen

Entscheidungsprozessen darzustellen. Diese Prozesse wie *Knowledge Discovery in Databases*, *CRISP-DM*, *Foundational Methodology for Data-Science* oder *Team Data-Science Process* (vgl. Foroughi und Luksch 2018, S. 10) haben einen hohen Fokus auf der Datenanalyse. Diese Modelle ähneln sich stark und konnten daher vereinfachend zusammengefasst werden. Da Datenwertschöpfungsketten individuelle Schwerpunkte aufweisen können, reicht eine starre Definition der Datenwertschöpfungskette allerdings nicht für alle Anwendungsfälle aus. Durch die modulare Erweiterbarkeit des Evaluationsmodells könnte das Kennzahlensystem für besonders relevante Datenprodukte auch erweitert werden. Die *Total Cost of Ownership* (TCO) ist ein äußerst exakter Ansatz, um reale Kosten zu ermitteln. Innerhalb dieser Berechnung können die Gesamtlebenszykluskosten eines Datenprodukts betrachtet werden. Diese Betrachtung erfordert erheblichen Aufwand und erscheint lediglich für ausgewählte Datenprodukte sinnvoll.

Total Cost of Ownership (TCO):

Zur Ermittlung der Total Cost of Ownership existieren verschiedene Berechnungsmodelle (vgl. Marx Gómez et al. 2009, S. 138). Die Kostenbestandteile werden funktional in direkte und indirekte Kosten (vgl. Marx Gómez et al. 2009, S. 139) oder nach den Lifecycle-Phasen in Anschaffungskosten, Eigentums- und Betriebskosten sowie Stilllegungskosten (vgl. Verbeke et al. 2017, S. 356) unterteilt (siehe Tab. 7.1).

Anschaffungskosten	Eigentums- und Betriebskosten	Stilllegungskosten
Software-Kosten einschließlich Erstanschaffung, Upgrade, geistiges Eigentum und Lizenzgebühren; Hardware-Kosten, einschließlich Erstanschaffung und Wartung; Netzwerk- und Sicherheitskosten Datenkosten einschließlich Kosten für den Erwerb externer Daten; Kosten für Modellentwickler*innen wie Gehälter und Schulungen	Kosten für Modellmigration und Änderungsmanagement; Kosten für die Einrichtung des Modells; Kosten der Modellausführung; Kosten für die Modellüberwachung; Supportkosten (Fehlersuche, Helpdesk etc.); Versicherungskosten; Modellpersonalkosten wie Gehälter und Schulungen Modellierung von Upgrade-Kosten; Modellierung der Kosten für Ausfallzeiten	Deinstallations- und Entsorgungskosten; Kosten für Wiederbeschaffung; Kosten für die Archivierung

Tab. 7.1: Beispielhafte Kostenanteile der TCO (vgl. Verbeke et al. 2017, S. 356)

Die TCO könnten auch als Basis der Kostenbetrachtung des ROI genutzt werden (7.1):

$$ROI_{DWK} = \frac{BVI_{DWK}}{TCO_{DWK}} \times 100 \tag{7.1}$$

Der Vorteil der TCO-Berechnung liegt im Detaillierungsgrad; als nachteilig ist der hohe Aufwand zu bewerten, der innerhalb des Forschungsprojekts nicht abgebildet werden konnte. Es wird empfohlen, diesen Aufwand bei kostenintensiven Datenanalysen nur dann zu betreiben, wenn sie einen hohen möglichen Geschäftswert für Anwendende bieten. Gleichzeitig ist hier auf eine fehlende Standardisierung von Datenwertschöpfungsketten in der Literatur hinzuweisen, die sich in den Ergebnissen der Literaturrecherche durch verschiedene Datenwertschöpfungsketten-Definitionen

und Canvas-Modellen offenbart. Neben einer vereinfachenden Zusammenfassung bestehender Modelle konnte diese Arbeit vorhandene Datenwertschöpfungsketten oder Canvas-Modelle um einen wesentlichen Bestandteil erweitern, nämlich den der objektiven Bewertungskriterien durch ein Kennzahlensystem. Die Evaluation deckte indes auch auf, dass das Aufführen zu vieler Variablen das Detaillieren der Datenprodukte erheblich erschwert und so zu einer längeren Bearbeitungszeit durch Evaluationsteilnehmende und weniger Rückläufen führen kann. Aus diesem Grund ist eine weitere Vereinfachung des Modells ratsam. Um eine bessere Übertragbarkeit sicherzustellen, wäre es zu empfehlen, die Befragung nicht nur auf die Anwendungsdomäne Offshore-Wind zu beschränken. Größere domänenunabhängige Befragungen könnten dieser Limitierung begegnen und eine Änderung der vorhandenen Module anregen, damit so das Evaluationsmodell weiter vereinfacht werden kann.

Um die Komplexität weiter zu verringern, sollte das Kategorisierungssystem für zukünftige Untersuchungen vereinfacht werden. Eine Überarbeitung der Kategorisierung auf 12 Kategorien könnte von Hevner und Chatterjee inspiriert sein, die *Menschen*, *Organisationen* und *Technologien* als Einflussfaktoren für Geschäftsanforderungen definieren (vgl. Hevner und Chatterjee 2010, S. 17). Die Kategorie Menschen ist in *Rollen*, *Fähigkeiten* und *Eigenschaften* aufgeteilt; die Kategorie Organisationen wird in *Strategien*, *Struktur und Kultur* sowie *Prozesse* untergliedert; die Kategorie Technologien umfasst *Infrastruktur*, *Anwendungen*, *Architektur*, *Entwicklung* und *Funktionalitäten*. Insbesondere die Technologie-Kategorie könnte weiter vereinfacht werden, etwa zu *Infrastruktur* (inklusive Architektur und Entwicklung), *Anwendungen* (inklusive Funktionalitäten und Entwicklung) und *Kommunikation*. Die qualitative Inhaltsanalyse der Ergebnisse der Interviews mit Expert*innen sowie die damit einhergehende Kategorisierung gaben eine erste Implikation dahingehend, dass dieses Kategorisierungssystem für Datenwertschöpfungsketten ebenfalls geeignet sein könnte. Durch die Vereinfachung der Kategorisierung könnte eine stärkere Fokussierung für die Diskussionsteilnehmenden erreicht werden, was die Evaluation beschleunigen und die Akzeptanz des Evaluationsmodells erhöhen würde.

Die Vielfalt der Datenprodukte stellt Herausforderungen für die Priorisierung und Auswertung dar. Eine Vielzahl der Datenprodukte befasste sich mit vorhandenen Kennzahlen, etwa der Leistung (DWT58/ VAT01: Anlagenleistung gemäß Nennleistungskurve) oder einem besseren Verständnis des Fehlerverhaltens von Anlagen oder Komponenten (DWT02: Welche Anlagen sind besonders auffällig, VAT04: How often does a specific system/component fail). Nicht alle Datenprodukte sind dabei zwangsläufig mit komplexen Methoden der Data-Science, sondern mittels einfacher Statistik zu lösen. Fragestellungen, die sich mit einfachen Fehlerstatistiken lösen lassen, können der BI zugeordnet werden (DWT32: Ist der Fehler schon häufiger aufgetreten? DWT33: Welche Fehlermeldungen treten besonders häufig auf?). Da es sich hierbei um ein Datenprodukt handelt, das in eine Optimierung der strategischen Planung mündet, ist die Frequenz der Nutzung nicht so hoch. Dem

stehen hohe einmalige und jährliche Kosten gegenüber, wenn Serienschäden auftreten. Auf das Windenergieanlagen-design werden Garantien von Herstellern in Verbindung mit Fünf-Jahres-Wartungsverträgen gegeben. Der Wartungsaufwand durch Fehler ist in den ersten Betriebsjahren zunächst am höchsten und nimmt dann zum Ende der Lebenszeit wieder zu; dieser Effekt wird als *Badewannen-Kurve* bezeichnet (vgl. Faulstich et al. 2011, S. 329 f.). Das Fehlerverhalten der Windenergieanlagen und ihrer Komponenten hat einen direkten Einfluss auf die Wirtschaftlichkeit eines Windparks. Während in dieser Bewertung der ROI für die Datenquelle als hoch bewertet wurde, ist aufseiten der Methodik und der Entscheidung ein niedriger ROI angesetzt. Ein Grund für den niedrigen ROI im Entscheidungswert besteht in der Fehlerentwicklung über die Zeit. Gleichwohl gibt es auch Hinweise auf Unzulänglichkeiten des klassischen Badewannenkurvenverlaufs von Fehlern, weshalb als eine mögliche Alternative eine leicht veränderte Fehlerkurve existiert (siehe Abb. 7.3), die *Premature-Serial-Failure* (PSF)-Kurve (vgl. Stiesdal und Madsen 2005, S. 4). Die PSF-Kurve basiert auf den Erfahrungen – (Henrik Stiesdal war zu diesem Zeitpunkt technischer Leiter von Siemens windpower) –, dass im Bereich der Windenergie Serienfehler auftreten, die einen vorzeitigen Verschleiß bewirken. Sie führen diese Tatsache auf den Reifegrad von Hauptkomponenten zurück, die häufig zum ersten Mal in diesen Umgebungsbedingungen eingesetzt werden (vgl. Stiesdal und Madsen 2005, S. 4).




Abb. 7.3: Badewannenkurve vs. Premature Serial Failure (vgl. Stiesdal und Madsen 2005, S. 4 f.)

Analog zu diesen Badewannen- oder PSF-Kurven müsste sich folglich auch der Entscheidungswert abhängig von der Position in der Kurve und dem Reifegrad der Komponenten ändern. Durch die Vereinfachung des Evaluationsmodells kann diese Komplexität aktuell noch nicht abgebildet werden; hier bietet sich Raum für weitere Forschung.

Es wurden ferner Datenprodukte identifiziert, die durch Verbesserungen des Datenmanagements oder durch Data-Governance gelöst werden können (OBE06: Statistik zu Einsätzen, DWT66: Wo steht die Windenergieanlage, wer ist am schnellsten da und kennt der*die Techniker*in sich mit dem Windenergieanlagentyp/-fehler aus?). Andere Datenprodukte umfassen zukünftige Entwicklungen etwa aus dem Bereich der vorausschauenden Wartung (VAT06: Are there any unusual/abnormal outliers/behavior changes detectable in the time series, e. g. temperature jumps or developments over

time) oder dem Nutzen hochaufgelöster Daten (OBE05: Wie verhalten sich die 10-Minuten-Statistiken im Vergleich zu den hochaufgelösten Daten?).

Einige Industriepartner erwähnten zudem den Aspekt, dass es Daten gebe, die nur analog vorliegen und zum Teil noch digitalisiert werden müssen. Diese Themen wurden in das Evaluationsmodell durch gewünschte (bisher noch nicht vorhandene) Datenprodukte aufgenommen. Neben diesen Rückmeldungen sind gewachsene Infrastrukturen zur Datennutzung bei allen Industriepartnern zu beobachten. Diese gewachsenen Datenstrukturen schließen die Existenz eines Single Point of Truth aus, wenn mehrere Organisationseinheiten mit lokalen Kopien von Daten arbeiten. Je nach digitalem Reifegrad einer Organisation kann das Datenmanagement dezentralisiert durch verschiedene Organisationseinheiten oder zentralisiert in Form einer Datenbank oder eines Data-Warehouses ohne einen Data-Lake durchgeführt werden. Datenmanagement und Data-Governance zur Definition von Rollen sind vonnöten, um die Datenqualität langfristig zu verbessern. Sie ermöglichen es, Entscheidungen datengetriebener zu gestalten. Im Bereich der Data-Governance ergeben sich ähnliche Herausforderungen wie in der Datenwertschöpfungskette selbst. Es gibt nicht *das eine* Data-Governance-System, das für alle Organisationen gleich gut verwendet werden kann.

Noninvasive Data-Governance begegnet dieser Herausforderung durch das Nutzen vorhandener Organisationsstrukturen (vgl. Seiner 2014, S. 103). Durch geringe Anpassungen werden etablierte Rollenmodelle und Zuständigkeiten um Aufgaben der Data-Governance erweitert. Eine Datenmanagement und -Governance-Strategie ist von entscheidender Bedeutung für eine erfolgreiche Optimierung der Datenqualität, die einen der wesentlichen Inputs für die Datenwertschöpfungskette repräsentiert. Eine weitere Rückmeldung bezüglich der Datenwertschöpfungskette lautete, dass eine hohe Datenqualität den Implementierungsaufwand der Datenanalysemethode reduziere, da weniger Aufwand in die Datenaufbereitung fließen müsse. Einige Organisationen werten Teile der Livedaten mithilfe eigener Datenauswertungs-Tools aus. Der Implementierungsaufwand lässt sich in die Datenaufbereitung, die Methodenumsetzung und die Analyse unterteilen. Bei den Datenanalysetypen kann zwischen Echtzeitanalysen, zeitlich vorgegebenen, ereignisgesteuerten und bedarfsgesteuerten Ad-hoc-Analysen unterschieden werden. Hier könnte das Evaluationsmodell die Datenanalyse zu stark vereinfachen. Auch CRISP-DM umfasst neben dem Geschäftsverständnis (*Business-Understanding*), der Modellierung (*Modeling*), der Evaluierung (*Evaluation*) und der Bereitstellung (*Deployment*) das Datenverständnis (*Data-Understanding*) sowie die Datenvorbereitung (*Data-Preparation*) (vgl. Chapman et al. 2000, S. 13). Zukünftige Studien könnten die Datenwertschöpfungskette durch weitere Details zu Datenanalysen wie Datenaufbereitung oder Modellierung erweitern.

Zur Visualisierung der Datenwertschöpfungskette gab es die Rückmeldung aus den Interviews mit Expert*innen, dass die Visualisierung des Sankey-Diagramms eingängig und übersichtlich zu gestalten sei. So sollten verschiedene Kategorien farblich abgesetzt werden und filterbar sein. Optische Brüche seien zu vermeiden, um die Visualisierung nicht unnötig zu verkomplizieren. Die Visua-

lisierungsschritte sollten so nachvollziehbar wie möglich sein. Diese Kommentare sind in die Erstellung der Visualisierung eingeflossen. Es wurden daher zusätzliche Filter und Farb-Codierungen im Software-Prototyp umgesetzt, für eine bessere Analyse der Evaluationsergebnisse.

7.4 Ausblick

Data-Science wurde als das „vierte Paradigma der Wissenschaft“⁵⁵ bezeichnet, von dem man sich Durchbrüche in einer Vielzahl von Forschungsbereichen versprach (Hey et al. 2009, S. 223). Ohne die Datenwertschöpfungskette vollständig zu verstehen, wird es (auch aufgrund immer komplexerer Methoden) zunehmend schwierig, den wahren Wert von Datenanalysen zu beurteilen und adäquate Prioritäten zu setzen. Die Notwendigkeit der Data-Science als neuer wissenschaftlicher Disziplin entstand ursprünglich aus dem Bedarf der Wirtschaft (vgl. Davenport und Patil 2012). Das Ziel dabei war es, die Wertschöpfung aus Daten für Organisationen sicherzustellen. Mit dem Aufkommen von Smartphones und Social Media wurden große Mengen an Daten verfügbar, die genutzt werden konnten, um Künstliche Intelligenz zu trainieren.

In der Vergangenheit gab es allerdings Fälle, bei denen Künstliche Intelligenz zu verschiedenen Diskriminierungen führte, etwa aufgrund der Herkunft (vgl. Sandvig et al. 2014, S. 5). Aus diesem Grund schlägt Sandvig vor, datenintensive Internetunternehmen (wie Google, Facebook etc.) zu kontrollieren und extern zu auditieren (vgl. Sandvig et al. 2014, S. 6). Diese Diskriminierungen, die tief in den Algorithmen verborgen sind, können noch schwieriger aufzudecken sein als klassische Formen der Diskriminierung (vgl. Sandvig et al. 2014, S. 17). Inwiefern zukünftige Algorithmen mit Ungenauigkeiten umgehen, bleibt abzuwarten.

OpenAI veröffentlichte ChatGPT im Jahr 2022 (vgl. Metz 2022). ChatGPT nutzt Generative Pre-Trained Transformer (GPT) -3.5, ein starkes neuronales Netzwerk, das auf dem Aufmerksamkeitsprinzip basiert (vgl. OpenAI 2022). Professor Jeremy Howard, dessen Arbeit ChatGPT inspirierte, erlaubte seiner Tochter, dem Chatbot Fragen zu verschiedenen Bildungsthemen zu stellen (vgl. Metz 2022). Er war begeistert zu sehen, wie sie durch die Antworten lernte, riet ihr aber, den Antworten nicht zu vertrauen, da sie anfällig für Ungenauigkeiten seien (vgl. Metz 2022). Assistenzsysteme und Chatbots wie ChatGPT könnten das Potenzial besitzen, die Art zu verändern, wie sich Menschen zukünftig Wissen erschließen. Menschen benötigen langwierige manuelle Auswertungen und Recherchen, um fundierte wissenschaftliche Arbeiten zu erstellen. Auch das Erfassen der relevanten Ergebnisse einer Online-Suchmaschine für eine Entscheidung könnte auf diese Weise automatisiert werden. So könnten Assistenzsysteme zukünftig den Weg von Daten zu Weisheit analog der

⁵⁵ Das erste Paradigma wird als Empirie definiert, das zweite als Analytik und das dritte Paradigma der Wissenschaft befasst sich mit der Simulation (vgl. Hey et al. 2009, S. 223).

DIKW-Pyramide beschleunigen. Auch entlang der Datenwertschöpfungskette bieten sich zahlreiche Möglichkeiten der Optimierung. Exemplarisch wurde diese Frage dem Chatbot und Assistenzsystem ChatGPT gestellt (siehe Abb. 7.4).

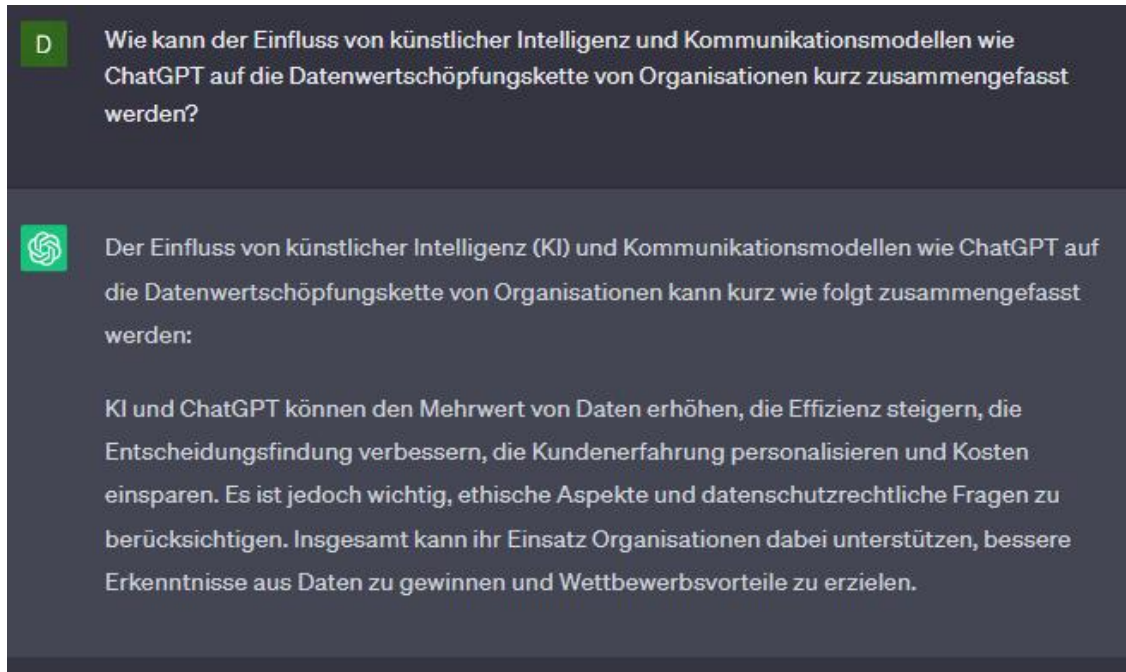


Abb. 7.4: ChatGPTs Antwort zum Einfluss von KI auf die Datenwertschöpfungskette von Organisationen (OpenAI 2023)

Es ist zu erwarten, dass Datenanalysen unter anderem durch Assistenzsysteme immer mehr Einzug in die Anwendungsdomänen halten werden. Anwendende und Data-Scientist*innen werden sich noch weiter aufeinander zubewegen. Data-Scientist*innen können das entwickelte Evaluationsmodell nutzen, um Datenwertschöpfungsketten zu bewerten, darzustellen und zu diskutieren, durch welche Werkzeuge (wie etwa Assistenzsysteme) Verbesserungen implementiert werden können. Dabei müssen Organisationen Kosten und Nutzen den möglichen Risiken und Fehleranfälligkeiten gegenüberstellen, um einem Missbrauch der Technik (etwa zum Betrug) oder einer Diskriminierung (etwa bei Einstellungsprozessen) entgegenzuwirken. Ebenfalls sollte berücksichtigt werden, dass ggf. Wertschöpfung in Black-Box-Systeme abfließt. Diese Systeme erfüllen ihren Zweck, ohne dass Anwendende im Detail verstehen, wie sie funktionieren (vgl. Skiena 2017, S. 206). Datenwertschöpfungsketten sind für die datengesteuerte Entscheidungsfindung und Prozessautomatisierung unerlässlich. Die Auswahl von Datenprodukten, die für Kund*innen sowie Anwendende Mehrwert schaffen, ist dabei entscheidend.

Die in dieser Arbeit entwickelten Artefakte wie die Datenwertschöpfungsketten-Ontologie und das Bewertungs- und Evaluationsmodell ermöglichen eine Visualisierung und Analyse der Datenwertschöpfungskette. So trägt diese Arbeit dazu bei, das Wissen über die Wertschöpfung aus Daten zu vergrößern und den wissenschaftlichen Diskurs anzuregen. Auf Basis dieser Ergebnisse wird es Aka-

demiker*innen und Praktiker*innen ermöglicht, Datenwertschöpfung zu bewerten. Dies hilft bei der Priorisierung von Zielen für die digitale Transformation von Organisationen und Forschung. Im Beispiel der vorliegenden Arbeit unterstützt das entwickelte Evaluationsmodell bei der Optimierung des Datenmanagements von Vattenfall und der Deutschen Windtechnik; auch Ocean Breeze konnte relevante Impulse für die Verbesserung ihrer Datenwertschöpfungskette erhalten. Ramboll beabsichtigt, das entwickelte Modell innerhalb seiner Beratungstätigkeiten einzusetzen, und Vattenfall möchte das Modell auch für andere Kraftwerksprojekte außerhalb von Offshore-Windparks nutzen. Aufgrund dieser Rückmeldung lässt sich eine hohe Relevanz für Praxis und Forschung ableiten.

Anhang

A Interviewleitfaden – Interview mit Expert*innen	143
B Ergebnisse Codierung Interviews mit Expert*innen (Runde 1)	148
C Ergebnisse Codierung Interviews mit Expert*innen (Runde 2)	209
D Codierleitfaden Datenwertschöpfungsketten Ontologie.....	211
E Datenprodukttable	213
F Evaluationsergebnisse Vattenfall	228
G Evaluationsergebnisse Ocean Breeze	236
H Evaluationsergebnisse Deutsche Windtechnik	244
I Freigaben	261

Hinweis: Im Rahmen der durchgeführten Interviews mit Expert*innen, der Transkription und der Auswertung der Evaluationsergebnisse wurde der Originalcharakter der Gespräche beibehalten, daher wurden hier nur minimale sprachliche Korrekturen vorgenommen, gleichzeitig kann deutsche und englische Sprache gemischt vorkommen.

A Interviewleitfaden – Interview mit Expert*innen

Einstieg (5 min)

Begrüßung und Dank für die Zeit

Vorstellungsrunde

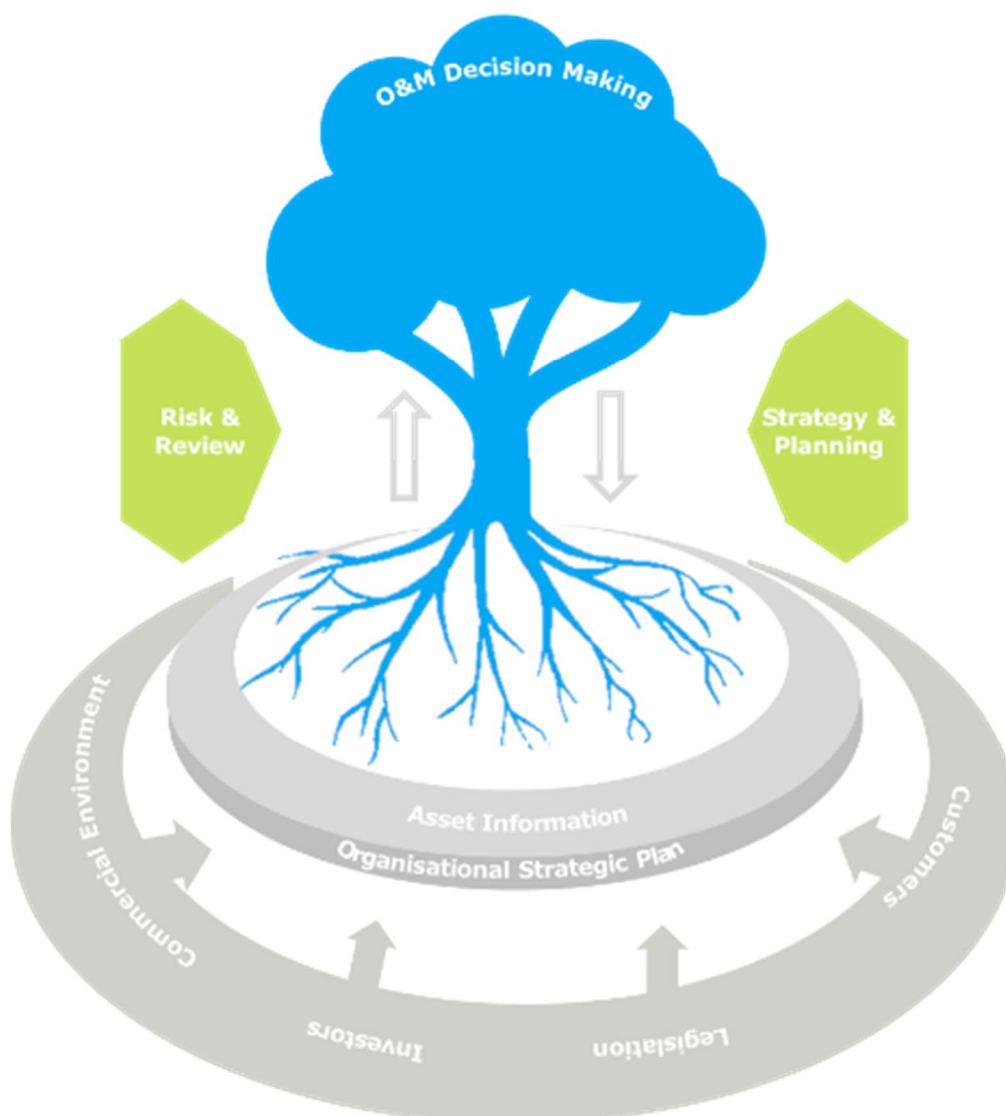
Datenschutzvereinbarung (Aufzeichnung des Gesprochenen, Anonymisierung)

Kurzer Umriss des Themas

Kurze Beschreibung des Interviewablaufs und der ungefähren Dauer

PART I: Einführung des Datenmanagement-Baums (10 min)

Ziel: Erläuterung Allegorie Baum: Wachstum und Nährstoffaustausch - Prinzip des Workshops erläutern.



PART II: Data Product Understanding (40 min)

Ziel: Datenprodukte identifizieren.

Wie werden Datenprodukte definiert? Welche KPIs muss ein DP erfüllen?

Welche Datenprodukte werden aus SCADA Daten generiert?

In welchem Organisationslevel entstehen die Datenprodukte?

Welche zusätzlichen Produkte sind gewünscht?

Wie definieren Sie/Ihre Organisation Datamanagement?

Welche Funktion/ Zielsetzung hat es? Welche Abteilungen sind involviert? Welche Aufgaben umfasst das Datenverwaltungssystem?

PART III: Data Process Understanding (Data Understanding and Data Preparation) (60 min)

Ziel: Bestehendes Datenmanagement-System verstehen. / Den Prozess von Rohdaten zu Datenprodukt verstehen. Erarbeitung von gewünschten Data Products auf Basis von SCADA und Berichten/Protokollen.

Welche Datenquellen werden genutzt?

Welche Datenaufbereitung wird verwendet?

Gibt es Modellierungswerkzeuge?

PART IIIa: Data Understanding

Welche Datenquellen werden genutzt?

Welche Form haben die Rohdaten? Welche Artefakte kommen von den Inspektionen zurück?

Wie werden die Rohdaten abgelegt und auf welcher Plattform werden sie zur Weiterverarbeitung zur Verfügung gestellt?

Werden die Daten vor der Weiterverarbeitung gesäubert/gefiltert?

Wie wird die Datenqualität sichergestellt?

Existiert eine historische Datenbank? Bitte beschreiben Sie den Aufbau, Inhalt und Nutzung der historischen Datenbank.

Was ist das Ziel der historischen Datensammlung?

Wer verwaltet die historische Datensammlung?

Welche Art von Daten wird in den Datenbanken gespeichert? (Berichte, Protokolle, elektronische Daten, Zeitreihen, ...)

Wo und wie werden die Daten gespeichert? (als Rohdaten oder nachbearbeitet? Hardcopy, Ordner, Cloud Datenbanken?)

Wie alt ist die Datensammlung?

Wie regelmäßig werden neue Daten hinzugefügt? Gibt es Lücken in der Sammlung?

Welche Data Products werden aus den historischen Daten gewonnen?

Business Understanding (Geschäftsverständnisphase)

Welche Daten kommen von den Inspektionen zurück (Berichte, Protokolle, elektronische Daten, Zeitreihen, ...)?

Werden die Berichte digitalisiert?

Wie beeinflusst das gewünschte Data Product die Wahl der Wartungsmethodik? (planned, corrective, predictive)

Data Acquisition and Data Understanding (Datenerwerbs- und -verständnisphase)

Wie verändern sich die Datenerhebung und Inspektionsintervalle über die Lebenszeit?

Kommen nach der Garantiezeit andere Data Products hinzu?

Werden die Prioritäten in den unterschiedlichen Phasen anders gesetzt?

Beschreiben Sie die Erhebung der SCADA Daten.

Welche SCADA Daten werden erhoben?

Wie werden sie erhoben?

Welche Auflösung haben sie?

Data Preparation

Wie werden die erhobenen Daten weiterverarbeitet?

What sort of data are available for analysis?

Wie wird mit unvollständigen Daten umgegangen?

Evaluation

Nutzt ihre Organisation ein CMS? Wenn ja, welches und wie wird es genutzt?

Welche Art von Daten sind im System enthalten? (Berichte, Protokolle, elektronische Daten, Zeitreihen, ...)

Welche Assets werden damit abgedeckt?

Werden die Daten innerhalb des CMS verarbeitet?

PART IV: Closing the Loop (Deployment) (60 min)

Ziel: Verstehen wie neue Erkenntnisse in Management- und Entscheidungsprozesse eingebunden werden.

Wie werden Verbesserungspotentiale innerhalb der Firma kommuniziert?

Wie werden Wartungsstrategien angepasst?

Resultieren aus den Ergebnissen neue Fragen?

Deployment

Für welche Entscheidungen werden die Datenprodukte genutzt?

Welche [Datenprodukte] sind Faktoren, die bei Managementbewertungen des Asset-Management-Systems berücksichtigt werden?

Welche Datenprodukte werden für die kontinuierliche Verbesserung der Instandhaltungsstrategien und des Entscheidungsfindungsprozesses verwendet?

Wie laufen aktuell Entscheidungsprozesse ab? Basierend auf welcher Grundlage werden Entscheidungen getroffen?

Wie werden datengestützte Entscheidungen des höheren Managements an die relevanten Stakeholder kommuniziert, um das DM-System/die Instandhaltungsmaßnahmen zu verbessern?

Werden alle geplanten Instandhaltungsroutinen regelmäßig überprüft, um die Genauigkeit der Aktivitäten und/oder die notwendige Zeit für die Durchführung sicherzustellen?

Welche Prozesse werden für die Identifizierung, Bewertung, Umsetzung und Kommunikation von Änderungen an Personen, Prozessen und Anlagen verwendet?

Wie steuert die Organisation geplante Änderungen, die sich auf das Erreichen der Ziele des Asset-Managements der Organisation auswirken können, und wie werden etwaige nachteilige Auswirkungen gemildert?

Leistungsbewertung und Verbesserung

Welche Datenprodukte verwenden Sie, um die Performance Ihrer Anlagen zu gewährleisten?

Wie überwachen, kontrollieren und bewerten Sie die Leistung ihrer assets?

Verwenden Sie KPIs?

Wie entwickeln / entscheiden Sie über KPIs?

Werden die verarbeiteten Daten im Sinne von Lessons Learned und Empfehlungen interpretiert?

Werden die gelernten Lektionen in die Optimierung der Instandhaltung umgesetzt? Wie werden sie umgesetzt?

Werden die optimierten Prozesse im nächsten Jahr neu bewertet (Follow-up)?

Wo sehen Sie die größten Herausforderungen bei der Etablierung eines gut funktionierenden Datenmanagements, um sicherzustellen, dass die Anlagen einen Wert liefern?

Könnten Sie die drei größten Herausforderungen nennen, die es zu überwinden gilt, um ein gut funktionierendes Datenmanagements zu etablieren?

Wo sehen Sie zukünftiges Verbesserungspotential, um besser mit ... (diesen zuvor erwähnte Herausforderungen) umzugehen? Welche Maßnahmen sind erforderlich? Haben Sie ein Beispiel aus der Praxis für mich?

Welches sind die nächsten Schritte bei der Entwicklung Ihres Datenmanagement-systems?

Wo sehen Sie Ihre Datenmanagement-Systeme in 5 Jahren?

Wie viele Verbesserungsthemen haben Sie auf Ihrer Liste?

Welches sind die wichtigsten?

Welche Schlüsselaktionen sind bereits in der Pipeline?

B Ergebnisse Codierung Interviews mit Expert*innen (Runde 1)

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
CH	M10	Datenprozess ist relativ undokumentiert und vor allem reaktiv	05'	Datenmanagementprozesse müssen definiert und dokumentiert werden, um weniger reaktiv zu arbeiten.
		Der Betreiber hat die Einstellung, die vorhandenen KPIs mit Vorsicht zu genießen, weil die Datenqualität nicht perfekt ist (vor allem durch unterschiedliche Servicereports über die gesamte Flotte), z. B. stand die Anlage wegen Fehler, Wetter oder Service	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
		Es gibt keinen definierten Rahmen oder definierte Prozesse für die Art, in der der Betreiber in Zukunft arbeiten will (für die neuen Sites)	05'	Datenmanagementprozesse müssen definiert und dokumentiert werden, um weniger reaktiv zu arbeiten.
	M12	Der neue Eigentümer will mehr Daten sehen, die allerdings schon vorhanden waren	04'	Organisationsveränderungen führen zu geänderten Erwartungen an Daten, Strategien und das Geschäftsmodell.
		Die verschiedenen Logistikdienstleistungen werden vom Betreiber eingekauft	01'	Es müssen viele interne/externe Stakeholdern mit unterschiedlichen Hintergründen in Prozessen und für Entscheidungen berücksichtigt werden.
		Durch den neuen Eigentümer gibt einen wesentlich detaillierteren Business-Plan	04'	Organisationsveränderungen führen zu geänderten Erwartungen an Daten, Strategien und das Geschäftsmodell.
		Durch die Übernahme mussten mehr Daten extern berichtet werden, die sowieso aufgenommen wurden	04'	Organisationsveränderungen führen zu geänderten Erwartungen an Daten, Strategien und das Geschäftsmodell.
	M13	Kein vernünftiges ERP-System, daher viel über Excel (führt zu verschiedenen Eingaben verschiedener)	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Viel Arbeit mit Excel-Tabellen	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Viele Informationen, die verteilt sind	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Zum Teil wissen wir gar nicht, wo die Datenquellen liegen	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
	M19	99 % der Daten/Informationen werden	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		aktuell manuell in Listen oder Systeme eingetragen		Zentralisierung von Daten erschwert dies zusätzlich.
		Datenaustausch und Knowledge-Sharing über lokale Speicherung, Online-Excel-Tabellen, <i>offene</i> firmeninterne Speicherung	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
	M32	IDs und Zeitstempel der Daten sind nicht sortiert in den Dateien. Manchmal sind die ID und der Name unterschiedlich zwischen den Dateien. Oft sind die Zeitstempel inhomogen und nicht synchron zwischen den Kanälen und Zeitreihen.	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
	M33	Die Status-Codes könnten evtl. auch Informationen für ein Histogramm geben-> Anzahl der meisten Fehler identifizieren, allerdings werden sie aktuell nicht einheitlich im ERP-System hinterlegt	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
		Livedaten zur Verfügung zu stellen, ist eine Herausforderung wegen der Datensicherheit (Firewalls etc.).	06'	Datensicherheit stellt eine Herausforderung im Datenaustausch dar.
		Manche Alarmer stehen nicht in den Servicereports der Betreiber. Da der Anlagenhersteller auch Services an den Windturbinen durchführt, diese Reports sind oft nicht im System hinterlegt.	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
		Manche Daten sind redundant	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
	M36	Bewertungskriterien – von der Forschung und Akzeptanzkriterien für die Industrie, auch für die Visualisierung	12'	Die Anforderungen der Data-Analystinnen und -analysten und der Anwendungsdomäne müssen vereinheitlicht werden.
	M38	Einige Datenprodukte sind laut Forschungspartnern nicht zentral für das Projekt, können aber erarbeitet werden, allerdings: - Da es relativ viele sind, könnte es zeitlich das Projekt sprengen - Die Ergebnisse werden ggf. nur als Draft erstellt	13'	Datenprodukte müssen für eine effiziente Abarbeitung innerhalb von WiSA priorisiert werden.
	M4	Das System ist nicht fest: Es sind unterschiedliche Betreiber von Onshore/Offshore-Windparks mit unterschiedlichen Organisationen und unterschiedlichen	01'	Es müssen viele interne/externe Stakeholdern mit unterschiedlichen Hintergründen in Prozessen und für Entscheidungen berücksichtigt werden.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Erfolgsniveaus involviert. Daher gibt es keine richtige oder falsche Lösung.		
		Es gibt noch Lücken und der Entscheidungsprozess hängt noch nicht eng mit dem Datenmanagement zusammen.	07'	Datenmanagement und Entscheidungen müssen kombiniert werden, um datengetriebene Entscheidungen zu ermöglichen.
		Es stehen zwei Gesellschaftsübernahmen an, bei denen zum Teil auch Strategien übernommen werden, die aber ggf. noch Anpassungen benötigen	04'	Organisationsveränderungen führen zu geänderten Erwartungen an Daten, Strategien und das Geschäftsmodell.
		Es wird bald ein neues ERP-System eingeführt, das Service-Management-System wird aktualisiert, es werden wesentliche Soll-Prozesse über das ERP-System und das Service-Management-System neu definiert	04'	Organisationsveränderungen führen zu geänderten Erwartungen an Daten, Strategien und das Geschäftsmodell.
	M41	Bei den Methoden gibt es Probleme: - Viele Punkte sind einfache statistische Auswertungen - Spalte AI impliziert den Projektfokus (27 Datenprodukte) - Fehlerfrüherkennung umfasst mehrere Methoden	13'	Datenprodukte müssen für eine effiziente Abarbeitung innerhalb von WiSA priorisiert werden.
	M43	Die Servicereports mit 80 000 Zeilen in einer Excel-Tabelle, das dauert; leider konnte es nicht mit Python automatisiert werden.	08'	Fehleranalysen können sehr umfangreich/kompliziert werden (aufgrund der Technik oder Datenlage).
	M5	Die Wartungsprotokolle können pro Anlage sehr unterschiedlich sein.	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
		Die Wartungsprotokolle werden in Word geschrieben, die Informationen daraus werden in Excel überführt. Die Daten werden gefiltert. Auch PowerPoint kommt zum Einsatz.	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Wartungsprotokolle werden im Spätsommer per Hand ausgewertet, es liegen Metadaten vor, die zentral in Excel ausgewertet werden können (z. B. Nachfüllmengen). Daraus werden die nötigen Maßnahmen zur Planung der nächsten Kampagne abgeleitet.	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M50	Die Pitch-Werte haben einen gewissen Bias zum Sollwert, den muss man berücksichtigen, um das Misalignment zu berechnen. Eine statistische Auswertung könnte auch helfen (Mittelwert + Standardabweichung)	15'	Standardabweichungen von Sollwerten müssen definiert werden, um die Daten besser interpretieren zu können.
		Es gibt eine gewisse Distanz (Medienbruch) zwischen Betriebsführung und operativem System.	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Netzbedingte Leistungsbeschränkung (Curtailment): Manchmal wird die Leistung absichtlich reduziert. Das muss im Assessment/in der Auswertung berücksichtigt werden, es gibt ein Curtailment-Log auf Parkebene, man kann aber auch zusätzlich den <i>Power Set Point</i> (Sollwert) ansehen. Wenn dieser weniger als 100 % beträgt, dann kann man von einem Curtailment ausgehen	14'	Netzanforderungen zur Leistungsbeschränkung haben einen Einfluss auf die Nennleistung, die berücksichtigt werden sollte.
		Vom Netz kommt bspw. die Anweisung, dass ein Park 50 % weniger ins Netz einspeisen soll. Daraufhin bekommen verschiedene Windenergieanlagen einen neuen Sollwert. Anhand des Sollwertes sieht man, welche Turbine heruntergeregt wurde. Sollwerte sind in den SCADA-Daten enthalten.	14'	Netzanforderungen zur Leistungsbeschränkung haben einen Einfluss auf die Nennleistung, die berücksichtigt werden sollte.
	M51	Datenerfassung: Informationen zu Stillständen von Anlagen gehen per E-Mail ein.	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
		Die Definition von Fehlern ist von Hersteller zu Hersteller unterschiedlich: Bei manchen greifen wir auf die Anlagensteuerung zu, um uns ein Bild vom Status zu machen, da sie keine Status-Codes liefern. Andere Anlagen stellen Satus-Codes zur Verfügung die dingfest sind und verwertet werden können. Es stellt ein beträchtliches Problem im deutschen Markt dar, tatsächlich auf die DNA der Anlage vorzudringen. Was uns also interessiert, ist eine	11'	Ein Problem ist der fehlende Zugriff auf Herstellerdaten, um größere Tiefe bei Datenverständnis und Dateninterpretation zu ermöglichen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Echtzeitdaten-Betrachtung, um den Kollegen, die diese Daten betrachten, eine Einschätzung zu ermöglichen.		
		Noch keine Möglichkeit, anderen über datengetriebene Entscheidungsprozesse Entscheidungsalternativen/Empfehlungen zur Verfügung zu stellen.	07'	Datenmanagement und Entscheidungen müssen kombiniert werden, um datengetriebene Entscheidungen zu ermöglichen.
		Wenn die Technik einen Reset der Anlage erfolgreich durchführen konnte, dann wird das Feedback zurückgegeben, dass der Fehler entstört wurde. Hier ist auch ein Medienbruch zwischen der Betriebsführungssoftware und dem operativen Service zu sehen. Die benötigten Informationen finden sich in E-Mails und in Excel-Tabellen wieder. Dies erschwert es, die Datenprozesse auf einem guten Fundament aufzubauen.	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
	M52	Ein ISP hat einige Datenschnittstellen, aber die Hardware gehört den Betreibern.	11'	Ein Problem ist der fehlende Zugriff auf Herstellerdaten, um größere Tiefe bei Datenverständnis und Dateninterpretation zu ermöglichen.
	M53	Aktuell werden verschiedene Stammdaten wie die Seriennummer der Windenergieanlage in verschiedene Systeme eingepflegt (z. B. ERP und in eine Excelliste), so können schnell Fehler entstehen	03'	Medienbrüche erschweren die Datenauswertung, z. B. durch manuelle Datenanalyse z. B. mit Excel. Fehlende Zentralisierung von Daten erschwert dies zusätzlich.
	M6	Der Informationsrückfluss ist nicht einheitlich und verbesserungswürdig	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
	M7	Alle Parks im Portfolio sind sehr unterschiedlich, auch kulturelle Unterschiede spielen eine Rolle	01'	Es müssen viele interne/externe Stakeholder mit unterschiedlichen Hintergründen in Prozessen und für Entscheidungen berücksichtigt werden.
		Das Zusammenspiel zwischen Anlagenintegrität und Standortaktivitäten ist verbesserungswürdig.	01'	Es müssen viele interne/externe Stakeholder mit unterschiedlichen Hintergründen in Prozessen und für Entscheidungen berücksichtigt werden.
		Es gibt eine große Mischung aus verschiedenen Fachrichtungen (Techniker*innen, Ingenieure/Ingenieurinnen, IT, Rechtsabteilung usw.)	01'	Es müssen viele interne/externe Stakeholder mit unterschiedlichen Hintergründen in Prozessen und für Entscheidungen berücksichtigt werden.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Es ist schwierig zu definieren, wo schlechte Qualität bei SCADA-Daten beginnt. Schlechte Qualität ist in Wartungsberichten leichter zu erkennen, wenn z. B. Informationen fehlen.	02'	Die Datenqualität ist schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrolliert.
	M9	80 Datenstränge im Verlauf von 60 s; einen kompletten Log auszulesen, ist zu aufwendig; es wird nur manuell gemacht, wenn ein Fehler auftritt.	08'	Fehleranalysen können aufgrund der Technik oder Datenlage sehr umfangreich und/oder kompliziert werden.
		Alle Fehlermeldungen sind individuell verschieden und die Störungen sind auch anders verknüpft (anderer Aufbau des Pitch-Systems)	09'	Die Fehlermeldungen im Windpark weichen je nach System ab.
		RDS-PP ist nicht implementiert, es gibt also keine unabhängige Nummerierung	10'	An Windenergieanlagen besteht häufig keine einheitliche Bezeichnung der Systeme und Komponenten (z. B. durch RDS-PP).
		Umrichter-Fehler sind schwer zu analysieren, da diese wiederum 1000 Gründe haben können	08'	Fehleranalysen können aufgrund der Technik oder Datenlage sehr umfangreich und/oder kompliziert werden.
DANA	M11	Generatorfehler, Hilfsmittel: 1) CMS, 2) WTC-Events (Base-Viewer-Daten): a. Lagertemperaturen (Warnungen, Alarme), b. Zustand des Schmierstoffspendersystems, 3) Kontrolle vor Ort (Probelauf mit akustischer und mechanischer Kontrolle, Altfettkontrolle, Offline-Schwingungsmessung, falls nötig/möglich Reparatur CMS-System). Indikationen durch 1. oder 2. werden durch Vor-Ort-Kontrolle abgesichert oder es wird sofort ein Reparatursatz geplant.	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
		Hilfsmittel zur Feststellung eines Getriebschadens: 1) (CMS/CDS), 2) Alarme und Events (a. Lagertemperaturen, b. Differenzdruck am Ölfilter), 3) Kontrolle vor Ort (Endoskopie o. Ä.). Indikationen durch 1. oder 2. werden üblicherweise durch eine Kontrolle vor Ort abgesichert.	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
		Hilfsmittel zur Feststellung eines Rotorhauptlager-Schadens: 1) Partikelzähler, 2) (CMS/CDS), 3) Kontrolle vor Ort (Endoskopie o. Ä.). Primär erfolgt die Detektion	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		der Schäden über den Partikelzähler. Die beiden anderen Hilfsmittel werden nur zur Bestätigung der Schäden verwendet.		Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
	M12	Bei Generatortausch mit einer Nichtverfügbarkeit von 1-2 Tagen wird deutlich mehr überwacht und Datenauswertung betrieben.	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
		Bei Großkomponenten wie dem Triebstrang wird deutlich mehr überwacht, das hat zu einer direkten Erhöhung der Verfügbarkeit geführt.	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
	M4	Großkomponententausch wäre ein Worst-Case-Szenario – Beispiel Getriebetausch	04'	Aufgrund ihrer Komplexität, ihres Einflusses auf die Verfügbarkeit der Windenergieanlage und besonderer Herausforderungen werden Großkomponentenschäden durch Sensoren identifiziert. Danach werden Daten (SCADA/CMS) tiefer ausgewertet, um den Schaden zum Schluss durch Vor-Ort-Kontrollen zu bestätigen.
	M7	SCADA-Daten werden auch für Vorhersagen verwendet, z. B. für die Diagnose der Komponenten. Beispielsweise werden Wetterdaten für die Diagnose und Abschätzung von Gondelvibrationen verwendet.	01'	SCADA-Daten werden von Betreibern für Vorhersagen genutzt.
		Wartungsdaten und Berichte (Pläne) werden verwendet, um Informationen über die Aktivitäten vor Ort zu sammeln.	03'	Wartungsprotokolle und Pläne geben Informationen über Aktivitäten vor Ort.
		Wettervorhersagen werden zur Unterstützung von Betriebsführungs- und Instandhaltungsprozessen genutzt	02'	Externe Datenanbieter werden genutzt, um die Planung zu verbessern (z. B. Wetterdatenanbieter).
	M9	Livedaten werden teilweise überwacht, dafür hat der ISP eigene Tools erstellt.	05'	Eigene Datenauswertungstools werten Teile der Livedaten aus.
DAQ	M1	Betreiber 1: Vollständiger Satz von SCADA plus alle internen Variablen - Ca. 5000 Kanäle (~1000 binäre Ausfallkanäle) - 80 WTG ab 2012 - Abtastrate bis zu 100 Hz im SQL-Server (nicht zeitgleich) - Extraktion von einem Jahr dauert einen Monat	03'	Eine Vielzahl an Datenkanälen (85-5000) kann relevant für eine Auswertung sein.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		- Servicereports vorhanden und Fehlercodes in Daten		
		Betreiber 2: SCADA aus OPC-Schnittstelle - Ca. 100 WEA - Abtastintervall 2–3 s (nicht gleichbleibend in der Zeit) - Ca. 100 Kanäle mit <i>typischen</i> SCADA-Daten - Servicereports vorhanden und Fehlercodes in Daten	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		ISP: - Unklar, welche Windenergieanlagen verwendet werden sollen - 10-Minuten-Mittelwerte (klassische und gängigste SCADA) - Keine historischen Daten - Serviceberichte vorhanden	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
	M10	UK Offshore-Windpark • 7 Meilen (ca. 12 km) von Kent, England (Ostengland) entfernt (in der Thames Mündung) • 100 Vestas V90- bis 3MW-Windenergieanlagen auf Monopile-Gründungen und Offshore-Substation (Anmerkung: die V90-Windenergieanlagen werden für den Betreiber in Zukunft nicht mehr relevant sein) • Nabenhöhe 70 m • In Betrieb seit 2010/2011 • Viele On- und Offshore-Windparks in der Nähe -> gute Infrastruktur • Der Park ist zu 100 % Eigentum des Betreibers • Vattenfall betreibt den Park, wartet ihn jedoch nicht, weil es sich um einen <i>Legacy</i> -Park handelt (Serviceorganisationen) • Park hat relativ gute Datenlage • <i>Level 2 Support</i> – Vattenfall relativ viel involviert • Daten entsprechen den Daten von neueren Windparks (evtl. 1–2 Sensoren mehr für eine Messgröße, aber ansonsten gleich)	07'	Ein Betreiber des <i>WiSA Big Data</i> -Konsortiums stellt für die Auswertung innerhalb des Projekts Daten eines 100 Windenergieanlagen starken Offshore-Windparks zur Verfügung.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M19	10-Minuten-Logs der Anlagen (allgemeine Anlageninformationen)	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Datenaustausch und Knowledge-Sharing über lokale Speicherung, Online-Excel-Tabellen, offene firmeninterne Speicherung	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Eigenes Gateway zur alleinigen Nutzung durch die technische Betriebsführung für Zugang zu Anlagensteuerungen in Planung, aktuell werden Gateways der Leitwarte genutzt.	09'	Datenzugriff auf die Anlagen wird durch Gateways geregelt. Die Leitwarte hat den Hauptzugriff.
		Eine Übersicht über Verträge und vertraglich vereinbarte Zielgrößen wird in Listenform geführt.	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, wie z.B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Individuell angelegte und gepflegte Listen zur Überwachung von (garantieren) Verfügbarkeiten.	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Individuell angelegte und gepflegte Listen zur Überwachung von Wartungsintervallen (vermutlich ebenfalls bald in Success-Map)	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Liste Anlagen-Logbuch-Pflege, Eintragen von Versanddatum, Monatsbericht und Verfügbarkeiten bei internen Service-Parks (die durch die technische Betriebsführung betreut werden)	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Selbsterstellte Excel-Listen werden für das Reporting verwendet	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Serviceberichte mit Informationen zu getauschten Ersatzteilen und dann manueller Abgleich mit alten Serviceberichten im Hinblick auf Gewährleistung	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Windprognosen über diverse Internetseiten	10'	Externe Dienstleistende unterstützen die Wartungsplanung z. B. durch Wetterdaten.
	M20	Google-Tabellen	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Wissensstand der Technik sehen wir in Moodle oder in einer selbst ausgearbeiteten Excel-Tabelle	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
	M31	Der ISP sendet eine Fehlerliste zu den zur Verfügung gestellten Daten	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Es können auch Daten einer Vestas V66 genutzt werden (drei Monate @ 10 Hz Daten aus der Software WEA-Doktor) allerdings sind keine Serviceberichte verfügbar. Potenziell können 1 Hz Livedaten von 10–15 Windenergieanlagen im Forschungsprojekt geteilt werden.	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Vestas V66-Daten über drei Monate <ul style="list-style-type: none"> • 10 Hz Auflösung • Beide Datensätze laufen aus WEA-Doktor (Forschungsprojekt in WiSA) ein 	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Zugang zu Livedaten möglich, Vestas V80-Daten über fünf Monate <ul style="list-style-type: none"> • 85 Kanäle • 1 Hz Auflösung 	03'	Eine Vielzahl an Datenkanälen (85–5000) kann relevant für eine Auswertung sein.
	M32	Die Bereitstellung der Service-Protokolle wurde besprochen. Das liegt beim ISP, es geht dabei auch um personenbezogene Daten, was eine Herausforderung	05'	Personenbezogene Daten in Serviceprotokollen stellen eine Herausforderung für das Teilen von Daten dar.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		bei der Freigabe der Daten sein könnte		
		Die Daten enthalten Zeitreihen-Daten, Element-Files und Field-Files	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Insgesamt wurden 3417 Kanäle als für WISA relevante Kanäle identifiziert. Die anderen wurden herausgefiltert	03'	Eine Vielzahl an Datenkanälen (85–5000) kann relevant für eine Auswertung sein.
		Livedaten-Stream kann vom Betreiber nicht zur Verfügung gestellt werden	04'	Nicht alle Betreiber stellen Livedaten zur Verfügung.
	M33	96 Kanäle 100 Windenergieanlagen V90 UK 2017–2019 3 Jahre 42/44 GB pro Jahr	03'	Eine Vielzahl an Datenkanälen (85–5000) kann relevant für eine Auswertung sein.
		Nicht alle 96 Kanäle sind so hoch aufgelöst (Temperaturdaten z. B.), manches ist redundant. Hochaufgelöst wäre eine Sampling-Rate von 5 s oder 10 s.	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Von 100 Windenergieanlagen sind die Daten vorhanden und von jeder Windenergieanlage 96 Kanäle, dazu drei Datentypen: Masterdaten, Servicereports und separate Daten über die Zeitreihen.	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
		Wir haben Alarmlogs als Zeitreihen zu jeder Windenergieanlage	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
	M4	SCADA-Daten und auch Service- und Einsatzberichte sollen zur Verfügung gestellt werden.	02'	Daten können strukturiert, semistrukturiert und/oder unstrukturiert vorliegen und hoch- oder niedrigaufgelöst sein. Ersteres liegt mit Messfrequenzen im kHz-Bereich vor, Letzteres mit Messintervallen von 5 s/10 s/10 min.
	M5	Nach einer Wartungskampagne gibt es ca. 20 000 Datensätze.	01'	Wartungskampagnen erzeugen viele Datensätze.
	M50	Es existiert eine Liste von interessanten Temperatur- und Drucksensoren. Aber es wäre einfach, eine bestehende Methode dann auch für andere Kanäle zu übernehmen. Interessant sind: Gondeltemperatur, der	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Druck des Pitch-Systems, Temperatur für einige Schaltschränke, Transformer-Öl-Temperatur, UVW-Phasen-Temperatur		
	M51	Datenaufbereitung in Excel mit anschließender manueller Analyse und Vergleich mit früheren Fehlern.	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
		Die Informationen, um welchen Schaden es sich handelt, werden in manuell erstellten Excel-Listen abgelegt.	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
	M6	Die Anlagendaten (Messwerte) können strukturiert geliefert werden.	06'	Strukturierte Windenergieanlagen stehen im Fokus für das Forschungsprojekt <i>WiSA Big Data</i> . Diese Datenquellen sollen nach Windenergieanlagentyp bewertet werden.
		Es ist unklar, ob zur Substation Daten zur Verfügung stehen. Primär sind die Windenergieanlagen in UK interessant.	06'	Strukturierte Windenergieanlagendaten stehen im Fokus für das Forschungsprojekt <i>WiSA Big Data</i> . Diese Datenquellen sollen nach Windenergieanlagentyp bewertet werden.
	M9	Die Datenquellen müssten nach Windenergieanlagentyp aufgelöst werden.	06'	Strukturierte Windenergieanlagendaten stehen im Fokus für das Forschungsprojekt <i>WiSA Big Data</i> . Diese Datenquellen sollen nach Windenergieanlagentyp bewertet werden.
	(blank)	Selbsterstellte Listen (99 % der Daten/ Informationen werden aktuell manuell in Listen/Systeme eingetragen)	08'	Viele lokale Listen in Form von Dokumenten im Netzwerk dienen der Wissensvermittlung. Ihre Inhalte decken ein weites Spektrum ab, z. B. relevante Sensoren, Fehlerlisten, Schadensarten und Fehleranalysen, vertragliche Details (garantierte Verfügbarkeiten), Verfügbarkeiten und Monatsberichte zu individuellen Windparks.
DM	M13	Eine gemeinsame Datenbank könnte dabei helfen, Informationen besser zu finden.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und die Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
	M19	Beim ISP gibt es einen Windparkordner für die Ablage sämtlicher Daten, Informationen, Dokumente (Kontakt Daten, Gutachten, Kabelpläne, Serviceberichte,)	03'	Es existiert ein Windparkordner für sämtliche parkspezifischen Informationen und Dokumente (Kontakte, Gutachten, Pläne und Serviceberichte). Anfahrtsdaten finden sich auch in der Flottenmanagement-Software.
		Data-Analysten-Fragen: Gibt es schon ein Datenbankkonstrukt?	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Data-Analysten Fragen: Wie können sämtliche Informationen gesammelt und übersichtlich aufbereitet werden?	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Welche Daten sind besonders relevant: - Anlagendaten (Steuerung und Service-Management-System) und daraus generierte Logbücher, Fehlerstatistiken, ... - Unterlagen Behörde, Versicherung, technische Richtlinien, zur Festlegung der Intervalle und Umfänge von Prüfungen sowie <i>letztes Durchführungsdatum, Intervall, Soll-Durchführungsdatum</i> und Abgleich Soll-Ist-Datum - Informationen in Schichtübergabe zu den Stillständen, Kommunikationsproblemen, ... - Informationen in E-Mails zu Stillständen, Kommunikationsproblemen, ... - Kontaktdaten sämtlicher Art - Durchführungsdatum Wartungen - Windprognosen - Art des getauschten Ersatzteils und Datum des (letzten) Austauschs	02'	Es gibt unterschiedliche Datenarten innerhalb der Betriebsführung und Instandhaltung: - Windenergieanlagendaten (aktuell: Steuerung, Historie: durchgeführte Wartungen, getauschte Komponenten, Schichtübergaben und Informationen zu Stillständen oder Kommunikationsproblemen), - Behördliche Auflagen - Versicherungen und technische Richtlinien - Kontaktdaten - externe Datenlieferanten (Windprognosen)
	M20	Anfahrts- und Schlüsselinformationen im Windparkordner oder bei der Flottenmanagement Software <i>Fleetview</i> von der Firma DKV	03'	Es existiert ein Windparkordner für sämtliche parkspezifischen Informationen und Dokumente (Kontakte, Gutachten, Pläne und Serviceberichte). Anfahrtsdaten finden sich auch in der Flottenmanagement-Software.
	M33	Datenauswertungen werden meist vom O&M-Manager selbst angefragt für spezifische Datensätze (kein Loop der Anfrage über die Organisation)	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
	M4	Es wird (vom ISP) ein präventiver Instandhaltungsingenieur eingestellt, der sich mit den Daten ausführlich beschäftigen wird und so lenken wird, dass <i>präventive Wartung</i> basierend auf den Daten umsetzbar wird.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M47	Den Grundaufbau eines Datenmanagements lernen und mit digitalisierten Datensätzen den Output kreieren, den der ISP für seine Analysen benötigt.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Stammdaten müssen gefestigt werden.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z.B. in einer Datenbank, Datawarehouse oder einem Data Lake als Projektziele.
	M51	Die Materiallisten entsprechen einer Lebenslaufakte, wo man sehen kann, was auch historisch bei der Anlage aufgetreten ist und welches Material zur Abstellung von Fehlern und zur Wartung genutzt wurde. Wenn bekannt ist, welche Teile im Umrichter getauscht wurden, können hiermit Verknüpfungen zu den Methoden hergestellt werden. Die Materiallisten können vom ISP mit den Echtzeitdaten zusammen geteilt werden.	04'	Materiallisten als Lebenslaufakte zeigen, welche Materialien bei der Instandhaltung und Entstörung von Anlagen verbraucht wurden. Für häufige Standardwartungen existieren ggf. abweichende Standardstücklisten.
		Digitalisierte Erfassung der Daten: Darin liegt die Wertigkeit des Datenproduktes. Während der Schichtübergaben werden aktuell die Informationen in Excel an die Folgeschicht übergeben. Es ist von Interesse, das Fehlerbild und die Häufigkeit des Auftretens des Fehlers in einer Datenbank zu sammeln. Das legt die Basis dafür, die Einschätzung der Expert*innen irgendwann in KPIs umzuwandeln und in Empfehlungen, die automatisch generiert werden können.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Für Standardwartungen existieren Standardstücklisten, die von den Materiallisten abweichen können	05'	Materiallisten als Lebenslaufakte zeigen, welche Materialien bei der Instandhaltung und Entstörung von Anlagen verbraucht wurden. Für häufige Standardwartungen existieren ggf. abweichende Standardstücklisten.
	M53	Aktuell gibt es Stammdatenverantwortliche, das wird zukünftig ausgebaut.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Data-Governance zu entwickeln, ist das wichtigste Know-how, das ihr inhouse entwickeln könnt; das umfasst Rollen und Prozesse, die ihr selbst entwickeln könnt.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Data-Warehouse oder Data-Lake befinden sich gerade im Aufbau bzw. die Fragestellung Data-Warehouse vs. Data-Lake ist eher eine Zukunftsfrage; wenn das Datenmanagement etabliert ist, kann im Ergebnis ein Data-Warehouse stehen.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Der Datenschutzbeauftragte ist bei allen Plänen für Prozesse und Datenmanagement-Aufbau zu integrieren, genauso wie die IT-Abteilung	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Der ISP optimiert gerade das Datenmanagement und möchte dabei auch Bestandteile wie den Qualitätssicherungsprozess inklusive der benötigten Rollen (Data-Stewards etc.) etablieren.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Durch das Etablieren von Datenmanagement kann Business-Intelligence (BI) durchgeführt werden	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Etablieren eines Single Point of Truth für die Datenquellen	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
		Internes Marketing ist wesentlich, damit alle Stakeholder eingebunden werden und mithelfen, die Datenqualität hochzuhalten, der ISP hat dazu E-Mail-Newsletter etabliert.	01'	Ein Industriepartner hat die Erhöhung der Datenqualität (durch neue Rollen und Data-Governance) und Zentralisierung von Daten durch Datenmanagement z. B. in einer Datenbank, einem Data-Warehouse oder einem Data-Lake als Projektziele.
DP	M19	Beantwortung der Frage: Welche Aktionen müssen erfolgen, wann müssen Parameter wieder zurückgestellt werden?	02'	Parameter, die innerhalb der Fernüberwachung zurückgestellt werden müssen, sollten klar ersichtlich sein.
		Beantwortung der Frage: Welche Anlagen sind besonders auffällig?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Beantwortung der Frage: Welche Bauteile müssen stärker ausgelegt werden (wo besteht erhöhter Verschleiß und Handlungsbedarf)?	03'	Ein Projektziel für einen Industriepartner ist es herauszufinden, welche Bauteile zur Wartungsreduzierung verändert werden müssen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Beantwortung der Frage: Welche Fehler treten wiederholt auf?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Bestehen Gewährleistungsansprüche, auf die ggf. bei der Rechnungsstellung/-freigabe geachtet werden muss?	07'	Bei Fehlermeldungen entsteht die Frage des Gewährleistungsanspruches.
		Besteht Kommunikation zu der Anlage?	04'	Ein Primärziel ist es zu prüfen, ob die Datenverbindung zum Windpark vorhanden oder gestört ist.
		Besteht noch ein Gewährleistungsanspruch?	07'	Bei Fehlermeldungen entsteht die Frage des Gewährleistungsanspruches.
		Der Service muss häufig folgende Frage beantworten: Wie ist der Schulungsstand der Supporter (Level 2 und 3)?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Die Arbeitsvorbereitung muss häufig die Frage beantworten: Kann vor Ort gearbeitet werden (z. B. aufgrund von Witterungsverhältnissen)?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Die Arbeitsvorbereitung muss häufig die Frage beantworten: Welches Material wird gebraucht?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Die Leitwarte muss häufig folgende Frage beantworten: Welche Teams sind vor Ort?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Die Leitwarte muss häufig folgende Frage beantworten: Wie ist der Kommunikationsstand?	04'	Ein Primärziel ist es zu prüfen, ob die Datenverbindung zum Windpark vorhanden oder gestört ist.
		Die Leitwarte muss häufig folgende Frage beantworten: Wie oft ist der Fehler in den letzten 8 h, 24 h, 48 h bereits aufgetreten?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Die Technik muss häufig die Frage beantworten: Was muss geschehen, damit der Fehler zukünftig nicht weiterhin auftritt?	06'	Eine zentrale Frage lautet: Wie können Fehler zukünftig vermieden werden, um die Wartung zu optimieren?
		Die Technik muss häufig folgende Frage beantworten: Gibt es Anlagenoptimierungen?	06'	Eine zentrale Frage lautet: Wie können Fehler zukünftig vermieden werden, um die Wartung zu optimieren?

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Erreicht die Anlage/der Park die garantierte Verfügbarkeit? Wenn nein, ist eine Malus-Zahlungen notwendig; wie hoch ist diese?	12'	Für Hersteller und/oder Wartungsfirmen werden Strafzahlungen für nicht erreichte vertragliche Verfügbarkeit fällig.
		Fragen bei der Schichtübergabe: Fragen zu langanhaltender/schichtübergreifender Teamunterstützung (schalltechnische Vermessung) Wann ist ein Team vor Ort? Welche Priorität hat die Anlage/Arbeit? Ist der Fehler schon häufiger aufgetreten?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Ist der Zugang zur Anlage gewährleistet?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Ist ein Team verfügbar?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Ist eine Anlage aktuell mit Warnmeldungen, wiederholten Fehlermeldungen auffällig? Wenn ja, hat das zuständige Serviceorganisationen schon einen Einsatz geplant?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Können anstehende Arbeiten oder Mängel mit abgearbeitet werden?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Können Mängel bei anstehenden Arbeiten oder Fehlereinsätzen mit abgearbeitet werden?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Läuft die Anlage oder steht sie in Störung?	10'	Der Anlagenstatus ist ein KPI für die Betriebsführung und Instandhaltung.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Muss der Direktvermarkter oder eine andere Partei über die Arbeiten informiert werden?	11'	Die Kontaktperson und Informationspflicht vor den Arbeiten für die verschiedenen Windparks ist eine wichtige Information für die Arbeitsvorbereitung.
		Perfomrt die Anlage gemäß Nennleistungskurve etc.?	13'	Eine Frage lautet: Entspricht die Leistung der Windenergieanlage der Nennleistungskurve?
		Sind an Tag X (weitere) Arbeiten in dem Windpark/an der Anlage geplant?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Sind Leiter und Befahranlage freigegeben/geprüft oder gibt es andere Sicherheitsbedenken/Einschränkungen?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Sollten die Arbeiten nicht angekündigt sein und/oder in der Arbeitsfreigabeliste stehen: Dürfen die Arbeiten stattfinden oder muss das Team wieder abreisen?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Success-Map, Entwicklung eines eigenen Fristenmanagement-Tools für und durch die technische Betriebsführung, Hinterlegung von Informationen zu allen Gutachten (Intervall, Grundlage für Notwendigkeit des Gutachtens (BImSchV-Bescheid, Versicherungspolice, ...) Durchführungsdatum, nächstes Plandatum, ...)	08'	Die geplanten Wartungen umfassen z. B. Ölwechsel, Einhaltung von Wartungsintervallen und -umfang sowie Inspektionen (Gutachten wiederkehrender Prüfungen).
		Wann ist ein Störungseinsatz geplant und ist die Fehlerursache bekannt?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Wann sind Wartungsarbeiten geplant (im Hinblick auf Einhaltung des Intervalls oder zur Klärung der Mängelarbeit)?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Wann wurde der letzte Ölwechsel durchgeführt? - Sind durchgeführte Ölwechsel Vertragsbestandteil oder nicht?	08'	Die geplanten Wartungen umfassen z. B. Ölwechsel, Einhaltung von Wartungsintervallen und -umfang sowie Inspektionen (Gutachten wiederkehrender Prüfungen).
		Wann/Wie oft wurden Teile getauscht?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Was sind mögliche Ursachen für die Verzögerungen während der Instandsetzung?	09'	Eine weitere wichtige Information als Ergebnis aus dem Forschungsprojekt wären Verzögerungsursachen in der Instandsetzung.
		Welche Gutachten müssen in welchen Intervallen angefertigt werden? Wer ist dafür verantwortlich (technische Betriebsführung/Service)?	08'	Die geplanten Wartungen umfassen z. B. Ölwechsel, Einhaltung von Wartungsintervallen und -umfang sowie Inspektionen (Gutachten wiederkehrender Prüfungen).
		Welche Maßnahmen wurden schon zur Behebung eines Problems getroffen (z. B. Kommunikationsverlust) und was liegt in meinem Verantwortungsbereich?	14'	Für die Betriebsführung und Instandhaltung ist es wichtig, eine Übersicht über vertragliche Pflichten und Zuständigkeiten zu haben.
		Welche Priorität hat die Anlage (Verfügbarkeit)?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Welche Qualifikationen haben die Teammitglieder?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Welche sonstigen Pflichten habe ich als Betriebsführer/-in gemäß Vertrag? (Grünpflege, ...)	14'	Für die Betriebsführung und Instandhaltung ist es wichtig, eine Übersicht über vertragliche Pflichten und Zuständigkeiten zu haben.
		Welche Umrichter-Fehler kommen am häufigsten vor?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Welche Umrichter-Typen verursachen die meisten Fehler?	01'	Die Fehlerhäufigkeit im Windpark pro Anlagentyp, pro Anlage und pro Komponente ist von großem Interesse für die Betreiber.
		Wer ist für die Abarbeitung der Mängel verantwortlich?	14'	Für die Betriebsführung und Instandhaltung ist es wichtig, eine Übersicht über vertragliche Pflichten und Zuständigkeiten zu haben.
		Wer ist mein Ansprechpartner (Netzbetreiber/ Energieversorgungsunternehmen, Grundstückseigentümer, Kunde, Direktvermarkter, Wartungsorganisationen, ...)?	11'	Die Kontaktperson und die Informationspflicht vor den Arbeiten für die verschiedenen Windparks sind wesentliche Informationen für die Arbeitsvorbereitung.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Wer ist mein richtiger Ansprechpartner?	11'	Die Kontaktperson und die Informationspflicht vor den Arbeiten für die verschiedenen Windparks sind wesentliche Informationen für die Arbeitsvorbereitung.
		Werden die Daten in das Service-Management-System übertragen oder gibt es Probleme bei der Datenübertragung?	04'	Ein Primärziel ist es zu prüfen, ob die Datenverbindung zum Windpark vorhanden oder gestört ist.
		Werden die Wartungsintervalle und der Wartungsumfang eingehalten?	08'	Die geplanten Wartungen umfassen z. B. Ölwechsel, Einhaltung von Wartungsintervallen und -umfang sowie Inspektionen (Gutachten wiederkehrender Prüfungen).
		Wie ist die Windvorhersage für den Zeitraum, zu dem die Arbeiten angekündigt wurden, und dürfen die Arbeiten freigegeben werden (Ertragsausfall vs. Dringlichkeit der Arbeiten)?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Wie lange wird die Ersatzteilbeschaffung/Entstörung dauern?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Wurde der Mangel bereits abgearbeitet?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Wurden die Mängel nach Zeitraum X abgearbeitet oder besteht der Mangel weiterhin?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
	M20	Beispiel Mängelbearbeitung: Wann wird diese durchgeführt, ist Material bestellt und wo liegt es? Wenn fertig: Sind die Listen zurück und korrekt?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Verfügbare Techniker*innen sehe ich im Personalplan (Google-Tabelle)	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Welche Techniker*innen habe ich zur Verfügung und über welches Wissen verfügen sie?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Welches Material könnte benötigt werden? Hat das Team etwas im Auto oder kommen sie noch an einem Lager vorbei?	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
		Wo steht die Windenergieanlage, wer ist am schnellsten da und kennt der/ Techniker/-in sich mit dem Windenergieanlagentyp/-fehler aus	05'	Die Arbeitsplanung führt geplante Arbeiten durch, kümmert sich um die Prioritäten, Verfügbarkeit und Qualifikation von Teams und Einsatzbedingungen vor Ort (Zugänglichkeit), die Materialbeschaffung (inklusive Vorlaufzeiten) sowie Gewährleistungsansprüche und die Zuständigkeit.
G	M10	Der Betreiber hat als Ziel, Datenprodukte zu erstellen, die sich auf andere Anlagen übertragen/anwenden lassen, auch wenn sie anhand von alten Anlagen produziert wurden.	05'	Es ist zu klären, für welche Fragestellungen welche Datenqualität benötigt wird und wie sich Datenanalysemethoden übertragen lassen (beispielsweise auf andere Windenergieanlagentypen oder Windparks).
		Der Betreiber ist besonders daran interessiert, für welche Fehlerursachen und Zusammenhänge hochfrequente Daten erforderlich sind und für welche 10min-Average-Daten ausreichen. Beispielsweise besteht die Vermutung, dass bei Temperaturdaten keine hochfrequenten Daten notwendig sind.	05'	Es ist zu klären, für welche Fragestellungen welche Datenqualität benötigt wird und wie sich Datenanalysemethoden übertragen lassen (beispielsweise auf andere Windenergieanlagentypen oder Windparks).
		Der Betreiber möchte Maintenance-Strategien entwickeln, damit Serviceverträge individueller geschlossen werden können	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Der Betreiber will seine Prozesse und die eigene Handhabung von Daten stark ändern und deutlich mehr organisieren.	06'	Das Datenmanagement und die Data-Governance inklusive der Rollen sollen verbessert werden.
		Ein Datenprodukt, das die Qualität der Servicereports beschreibt, sollte aufgenommen werden (wichtig, da diese die Daten für die <i>Failure Mode, Effects</i>	05'	Es ist zu klären, für welche Fragestellungen welche Datenqualität benötigt wird und wie sich Datenanalysemethoden übertragen lassen (beispielsweise auf andere Windenergieanlagentypen oder Windparks).

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<i>and Criticality Analysis</i> liefern).		
		Ermitteln der systemrelevanten KPIs bzw. der kritischen KPIs	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M11	Grundsätzlich haben sie eine BSH-Genehmigung für 20 Jahre. Vorerst bis 2027 in Betrieb, es wird daran gearbeitet, die Genehmigung bis 2043 zu verlängern	02'	Eine Laufzeitverlängerung des Windparks ist ein Ziel für einen Betreiber.
	M12	Beispiel Korrosion in den Blattlagern: Hier gibt es Probleme, dass Bolzen brechen, es wäre schön, das pro aktiv zu erkennen. Dafür wird ein Schraubenbruchsensor eingesetzt, um akustisch wahrzunehmen, ob ein Bolzen getauscht werden muss	03'	Wenn Daten nicht zur Verfügung stehen, müssen weitere/neue Sensoren installiert werden.
	M19	Beantwortung der Frage: Wer ist der Betreiber /technische Betriebsführung/Supporter/Level-2-/ Level-3-Ansprechpartner? (entstehen Probleme durch Zeitverschiebung (Ansprechpartner?)	08'	Vertragsinformationen und Ansprechpartner, intern sowie extern, müssen abrufbar sein.
		Beantwortung der Frage: Wie ist die Qualität der Verbindung zu den Parks? (Traffic, Verbindungsabbrüche, zur Verfügung stehende Bandbreite)	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M32	Anhand der Daten voraussagen, wann der gleiche Fehler erneut auftritt. Diese Frage der Fehlerfrüherkennung treibt den Betreiber stark um. Ein Problem sind Fehlermuster im Getriebe (diese Komponente ist auch im Datensatz enthalten)	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M38	Zentraler Punkt für das Forschungsprojekt ist die Fehlerfrüherkennung (Aussage Forschungspartner)	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M44	Der Demonstrator muss die Analysen zeigen und verdeutlichen, wie eine Entscheidungsunterstützung aussehen könnte; das kann aber nur für ausgewählte Fragestellungen umgesetzt werden.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M47	Herausfinden, welche Daten in WiSA digitalisiert werden müssen.	09'	Daten zur Digitalisierung müssen priorisiert werden.
	M50	Die Datenanalyse sollte auf Basis einer Komponentenpriorisierung stattfinden.	04'	Fehleranalysen sollen durch bessere Strukturierung der Daten bezogen auf spezifische Komponenten oder Anlagentypen ermöglicht werden.
		Leistungselektronik der Umrichter ist auch eine wichtige Komponente, die hier betrachtet werden sollte.	04'	Fehleranalysen sollen durch bessere Strukturierung der Daten bezogen auf spezifische Komponenten oder Anlagentypen ermöglicht werden.
	M53	Später, wenn das Datenmanagement etabliert ist, können dann andere Methoden der Data-Science genutzt werden	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M6	Beim <i>Big-Data-Ansatz</i> könnte der Betreiber mehr machen – z. B. bei Stark vernetzten Informationen Knock-on-Effekte von Fehlern identifizieren.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Der Betreiber arbeitet aktuell an FMECAs übergreifend für mehrere Parks. Es ist das Ziel, die Datenanalyse möglichst generell anzulegen und je Komponente Unterscheidungen für die jeweiligen Anlagentypen vorzunehmen.	04'	Fehleranalysen sollen durch bessere Strukturierung der Daten bezogen auf spezifische Komponenten oder Anlagentypen ermöglicht werden.
		Die Themen von WiSA Big Data sind aktuell hochgradig relevant für den Betreiber, da derzeit viel diskutiert wird, wie die vorhandenen Daten besser genutzt werden können.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Ein Ziel ist es herauszufinden, wo man hingucken muss und welche Spots die interessanten sind. Welche Fehler sind die kostenintensiven?	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Es wird nicht ein Algorithmus oder Datenprodukt erwartet, das alles beantwortet, sondern Einsichten, was geht und was nicht. Es wird erwartet, dass im Forschungsprojekt Aspekte beleuchtet werden, für die der Betreiber keine Zeit und keine Ressourcen hat, und dass Erkenntnisse geliefert werden. Der Industriepartner möchte auch attraktive Forschungsvorhaben für Masteranden/Berufseinsteiger schaffen.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Für welchen Park wird die Failure Mode, Effects and Criticality Analysis durchgeführt? - Die Ambition ist, nicht mehr parkspezifisch vorzugehen, sondern komponentenspezifisch. Man beschäftigt sich gerade damit, die Daten mit dem richtigen Modell zu verknüpfen (RDS-PP-Struktur).	04'	Fehleranalysen sollen durch bessere Strukturierung der Daten bezogen auf spezifische Komponenten oder Anlagentypen ermöglicht werden.
		Neuronale Netze können SCADA-Daten mit CMS-Daten anreichern	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M7	Das Datenanalyseteam möchte mehr aus den Daten herausholen, da die Zeit für die Forschung derzeit begrenzt ist.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Die Betriebsführungs- und Instandhaltungs-organisation will die technische Integrität ihrer Anlagen überwachen.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
	M9	Eine automatische Verfügbarkeitsanalyse wäre hilfreich.	07'	Für einen Betreiber ist ein Projektziel von WiSA Big Data die Automatisierung von aktuell manuellen Analysen.
		Eine Flottenauswertung wäre für den ISP im Sinne von Predictive Maintenance wichtig (Anlagenvergleich etwa bei Temperaturkurven oder Pitch-Winkel).	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
		Wartungsvorhersagen sollten nicht nur auf Erfahrungswerten, sondern auch auf Datenanalysen basieren.	01'	Es soll mehr aus den Daten herausgeholt werden, etwa durch Data-Science-Ansätze wie neuronale Netze z. B. für Zustandsüberwachung, neue Einsichten, Vergleich von Anlagen und Parks, verbesserte Vorhersagen (Fehlerfrüherkennung) und verbesserte Entscheidungen (z. B. Priorisierung von KPIs oder das Anpassen von Strategien oder Verträgen).
K	M52	Die Anlagenhersteller oder Betreiber haben mehr Kostentransparenz im Vergleich zu einem Serviceanbieter.	01'	Die Hardwarekosten für Sensornachrüstung sind nur durch Betreiber/Hersteller bewertbar.
		Hardwarekosten hauptsächlich beim Betreiber/Hersteller, nicht beim ISP, die meisten Werte sind nicht erhebbar	01'	Die Hardwarekosten für Sensornachrüstung sind nur durch Betreiber/Hersteller bewertbar.
		Kostenfaktor 1/3 onshore zu offshore	02'	Offshore-Windenergie ist im Vergleich zu Onshore-Windenergie nach Aussage eines Industriepartners um das Dreifache höher. ⁵⁶ .
		Value-Chain für den ISP schwer berechenbar auf der Kostenbasis	01'	Die Hardwarekosten für Sensornachrüstung sind nur durch Betreiber/Hersteller bewertbar.
KPI	M10	Der Betreiber arbeitet mit internen und externen KPIs. Die externen KPIs werden von Behörden/Politik definiert, die internen sind bestenfalls strenger als die externen.	05'	In der Betriebsführung und Instandhaltung von Windenergieanlagen wird zwischen internen (selbst definierten) und externen (durch Behörden/Politik vorgegebenen) KPIs unterschieden.
		Die wichtigste Kennzahl ist die Revenue-based Availability.	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Time-based Availability mit der Revenue zusammen (Bereich Performance and Bereich Finance) -> Revenue-based Availability	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).

⁵⁶ Diese Aussage wird u. a. vom 2022 Electricity Annual Technology Baseline unterstützt ([Index | Electricity | 2022 | ATB | NREL](#)).

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M12	Der Betreiber berechnet nicht das Kosten-Nutzen-Verhältnis, es wird aber eine Änderung der energetischen Verfügbarkeit bewertet	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Energetische Verfügbarkeit (KPI)	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Energetische Verfügbarkeit Hauptmaßzahl (KPI)?	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Risiken und Ausfallwahrscheinlichkeiten – Ausfallwahrscheinlichkeit wird vom Engineering anhand der Fehlerraten geschätzt und dann simuliert.	04'	Wichtige KPIs sind die Ausfallrate, die Ausfallwahrscheinlichkeit und die Ausfallzeiten für Komponenten und Windenergieanlagen.
		Tage der Nichtverfügbarkeit je Ausfall und Typ (Fokus Großkomponenten)	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Verfügbarkeit Kern-KPI	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Welche Anlagen sind im Stopp und warum (KPI)?	02'	Wichtige KPIs sind der Fehlertyp und bei welcher Anlage der Fehler auftritt.
		Welche Fehler treten auf?	02'	Wichtige KPIs sind der Fehlertyp und bei welcher Anlage der Fehler auftritt.
		Wie aufwendig sind die Fehler (Mean Time to Repair)?	03'	Ein wichtiger KPI ist die <i>Mean Time to Repair</i> .
	M20	Welche Windenergieanlage steht, welcher Windenergieanlagentyp und mit welchem Fehler?	02'	Wichtige KPIs sind der Fehlertyp und bei welcher Anlage der Fehler auftritt.
	M33	Ausfallraten und Ausfallzeiten	04'	Wichtige KPIs sind die Ausfallrate, die Ausfallwahrscheinlichkeit und die Ausfallzeiten für Komponenten und Windenergieanlagen.
	M5	Wichtig ist, dass der Ertragsausfall niedrig ist.	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
	M7	Wichtige KPIs (Verfügbarkeit, Leistung usw.) werden von SCADA abgeleitet.	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
	M9	Stillstandszeiten/Verfügbarkeit oder Servicekosten wichtige KPIs für die Geschäftsführung	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Verfügbarkeit (energetisch oder zeitlich)	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
		Wenn die Verfügbarkeit (energetisch oder zeitlich) nicht erreicht wird, zahlt der ISP Strafen	01'	Die Anlagen- bzw. Windparkverfügbarkeit ist die wichtigste Kennzahl (energetisch sowie umsatz- und zeitbasiert).
O	M10	Das Portfolio des Betreibers ist sehr breit, er bedient viele Arten von Windkraftanlagen.	04'	Ein Windpark-Portfolio kann aus unterschiedlichen Windenergieanlagentypen und -arten und verschiedenen Wartungsorganisationen bestehen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M11	Der Betreiber ist eine Folgefirma einer Windenergieanlagenentwickler- und -Betreibergesellschaft.	01'	Ein Betreiber betreibt einen Nullserien-Windpark, bei dem er sämtliche Gewerke entworfen, fabriziert und installiert hat. Dadurch wird ein detaillierter Zugriff auf die Daten ermöglicht.
		Der Park ist eine <i>Nullserie</i> .	01'	Ein Betreiber betreibt einen Nullserien-Windpark, bei dem er sämtliche Gewerke entworfen, fabriziert und installiert hat. Dadurch wird ein detaillierter Zugriff auf die Daten ermöglicht.
	M12	Weil der Betreiber die Root-Cause-Analyse selbst durchführen muss, hat er einen viel tieferen Einblick in die Daten.	01'	Ein Betreiber betreibt einen Nullserien-Windpark, bei dem er sämtliche Gewerke entworfen, fabriziert und installiert hat. Dadurch wird ein detaillierter Zugriff auf die Daten ermöglicht.
	M5	Die Effizienz der Teams (Stunden und Schichten) wird analysiert und wöchentlich in Technik-Meetings präsentiert. Die Teams werden auch gegeneinander verglichen.	02'	Die Effizienz von Betriebsführungs- und Instandhaltungsteams wird wöchentlich verglichen.
		Eine der Betreiberfirmen war gleichzeitig auch Entwickler der Anlagentechnik. Diese Organisation wurde mittlerweile aufgelöst und in eine Serviceorganisation überführt, die seit 2016 Aufgaben und Aufbau eines eigenen Engineerings übernahm. Dazu wurde die Wartung ebenfalls neu aufgesetzt	01'	Ein Betreiber betreibt einen Nullserien-Windpark, bei dem er sämtliche Gewerke entworfen, fabriziert und installiert hat. Dadurch wird ein detaillierter Zugriff auf die Daten ermöglicht.
		Es gibt es keinen geregelten Prozess zur Verbesserung. Das dokumentierte Feedback wird dann für die große Feedbackrunde am Ende der Kampagne nochmals herausgenommen. In einem Jahresgespräch werden die Lessons Learned durchgesprochen und in eine Task-Liste überführt.	03'	Feedback und Lessons Learned werden nach jeder Schicht festgehalten und nach jeder Kampagne in einer Feedbackrunde besprochen. In einem Jahresgespräch werden diese Lessons Learned in Tasks umgewandelt.
		Nach jedem Turn gibt es Lessons Learned und Feedback-Gespräche	03'	Feedback und Lessons Learned werden nach jeder Schicht festgehalten und nach jeder Kampagne in einer Feedbackrunde besprochen. In einem Jahresgespräch werden diese Lessons Learned in Tasks umgewandelt.
	M6	Sind alle Parks unterschiedlich betreut? Oder läuft es irgendwo zusammen? – Das ist unterschiedlich. Die Ambition ist, es zu vereinheitlichen. Das Control-Center ist zentral in Dänemark. Es gibt Entstörung (Troubleshooting) und geplante Wartung. Das	04'	Ein Windpark-Portfolio kann aus unterschiedlichen Windenergieanlagentypen und -arten und verschiedenen Wartungsorganisationen bestehen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Troubleshooting ist zentral, die geplante Wartung ist oft parkspezifisch. Die dritte Art von Wartung ist der Großkomponententausch.		
P	M12	Es gibt ein zweites Operation-Control-Meeting (wöchentlich extern mit dem ISP)	01'	Die Zusammenarbeit mit Unterauftragnehmern im Bereich der Betriebsführung und Instandhaltung wird durch Lastenhefte und Verträge geregelt. Zusätzlich wird der aktuelle Status bei wöchentlichen Meetings besprochen.
		Wöchentliches <i>Technical Query</i> -Meeting zum Durchsprechen der Fehler (inklusive des Managements des Betreibers)	01'	Die Zusammenarbeit mit Unterauftragnehmern im Bereich der Betriebsführung und Instandhaltung wird durch Lastenhefte und Verträge geregelt. Zusätzlich wird der aktuelle Status bei wöchentlichen Meetings besprochen.
	M19	Beantwortung der Frage: Welche Mängel sind vorhanden?	02'	Mängel werden bei Wartung, Inspektion oder Gutachten identifiziert und an die Instandhaltungsteams zur Mängelbeseitigung weitergeleitet. Diese Mängel werden dann in den geplanten Wartungs- und Inspektionskampagnen abgearbeitet.
		Inspektionsplanung (regelmäßige Begehung der technische Betriebsführung-Parks durch Begehungsteam, Nachhalten von Durchführungs- und Planterminen, Nachhalten, wann Mängelliste an Service gesendet, wann Inspektionsbericht an Kunden gesendet, ...)	02'	Mängel werden bei Wartung, Inspektion oder Gutachten identifiziert und an die Instandhaltungsteams zur Mängelbeseitigung weitergeleitet. Diese Mängel werden dann in den geplanten Wartungs- und Inspektionskampagnen abgearbeitet.
		Wurden beim Gutachten/bei der Wartung/der Inspektion Mängel festgestellt?	02'	Mängel werden bei Wartung, Inspektion oder Gutachten identifiziert und an die Instandhaltungsteams zur Mängelbeseitigung weitergeleitet. Diese Mängel werden dann in den geplanten Wartungs- und Inspektionskampagnen abgearbeitet.
	M5	Ein Lastenheft wird erstellt und der Umfang für den Dienstleister festgelegt. Zusammen geht man in die Diskussion zur Umsetzung. Es existiert ein langfristiger Vertrag mit dem*der Dienstleistenden.	01'	Die Zusammenarbeit mit Unterauftragnehmern im Bereich der Betriebsführung und Instandhaltung wird durch Lastenhefte und Verträge geregelt. Zusätzlich wird der aktuelle Status bei wöchentlichen Meetings besprochen.
		Wenn die Prüfung der entstörten Komponente bei der nächsten geplanten Wartung vorgesehen ist, wird diese dann auch noch einmal geprüft. Bei Störungen von Großkomponenten, z. B. einer ungeplanten Generatorreinigung, wird ein Vermerk im Protokoll gemacht und die Reinigung wird in der geplanten Wartung nicht wiederholt.	02'	Mängel werden bei Wartung, Inspektion oder Gutachten identifiziert und an die Instandhaltungsteams zur Mängelbeseitigung weitergeleitet. Diese Mängel werden dann in den geplanten Wartungs- und Inspektionskampagnen abgearbeitet.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Andersherum wird die geplante Inspektion die Nabe nicht überprüfen, wenn zu diesem Zeitpunkt bereits feststeht, dass der Großkomponententausch der Nabe kurz bevorsteht. Somit gibt es starke Abhängigkeiten zwischen geplanter und ungeplanter Wartung		
	M9	Messung des Verschleißes von Generatorbürsten (die Ergebnisse werden manuell über Tablets, in der Software von L-mobile aufgenommen)	03'	Vor-Ort-Messungen bei Serviceeinsätzen werden teilweise schon digital aufgenommen.
R	M11	3rd Level: Wenn Komponenten/Windenergieanlagen kaputt sind, wird der Auftrag an den ISP ausgegeben. Es gibt einen Prozess für den Komponententausch.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <p>1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2.</p> <p>2. Level-2-Support - Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72-h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt.</p> <p>3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung.</p> <p>4. Data-Science/ Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				<p>bei historischen Daten.</p> <p>5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um.</p> <p>6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.</p>
		<p>Erläuterung der Tageseinträge im Daily Dashboard (<i>Tageszeitung</i>). Daten: Wind- und Wellenvorhersage, Einspeisung, aktuelle/vergangene/anstehende Einsätze</p>	<p>04'</p>	<p>Ein tägliches Dashboard gibt Übersicht über den Windpark (Wetter, Einspeisung), den Status einzelner Anlagen und aktuelle und vergangene Einsätze.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Flussdiagramm: Bestätigung eines Schadens, Stillstand bis Tausch oder kontrollierter Weiterbetrieb.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support - Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Im Service wird zwischen 1st, 2nd und 3rd Level unterschieden (3rd Level ist beim Betreiber angesiedelt).</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/ Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M12	Bei der Entstörung bekommt der Betreiber vom ISP (1st and 2nd Level) eine Anfrage mit einem Grund (KPI) für den Ausfall.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <p>1. Level-1-Support - Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2.</p> <p>2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt.</p> <p>3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung.</p> <p>4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring-Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten.</p> <p>5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um.</p> <p>6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M19	Die Leitwarte muss häufig die Frage beantworten: Muss jemand ausrücken, um den Fehler zu beheben?	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Eintragen von bekannten, geplanten Arbeiten in die Arbeitsfreigabeliste, die der Leitwarte zur Verfügung steht; Information, wenn Arbeiten nicht freigegeben sind</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Lokale/firmeninterne Speicherung: • Ticketsystem • Schichtübergabe • Serviceberichte • Selbsterstellte Listen (99 % der Daten/ Informationen werden aktuell manuell in Listen/Systeme eingetragen)	05'	Es existieren Informationen zu Serviceaufträgen im Ticketsystem, zu Schichtübergaben, Service- und Einsatzberichten in Form von digitalen Daten. Zusätzlich wird eine Vielzahl manuell erstellter Listen verwendet.
		Regionalcenter: Einplanung von Teams/ Fragen zu spezifischen Anlagen/Fragen zu Windenergieanlagen-Resets	02'	Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen: 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
		Schichtblatt (<i>live</i>) ist dauerhaft parallel geöffnet	07'	Das Schichtblatt ist ein <i>Livedokument</i> , das die Schicht während ihrer Durchführung protokolliert.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Technik: technische Datenfragen/Fragen zu Windenergieanlagen-Resets/ Expertise</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Technische Betriebsführung (technische Betriebsführung oder Level 3): Kommunikationsprobleme und allgemeine Fragen zur Windenergieanlage	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sog. Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
		Ticketsystem für die Abarbeitung von Serviceaufträgen	05'	<p>Es existieren Informationen zu Serviceaufträgen im Ticketsystem, zu Schichtübergaben, Service- und Einsatzberichten in Form von digitalen Daten. Zusätzlich wird eine Vielzahl manuell erstellter Listen verwendet.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Zwischen einzelnen Arbeitsschichten findet eine Schichtübergabe statt, um den aktuellen Abarbeitungsstand und Herausforderungen zu übergeben.	05'	Es existieren Informationen zu Serviceaufträgen im Ticketsystem, zu Schichtübergaben, Service- und Einsatzberichten in Form von digitalen Daten. Zusätzlich wird eine Vielzahl manuell erstellter Listen verwendet.
	M20	Im Regionalcenter kommen Fragen aus allen Richtungen an und wir beantworten oder leiten die Fragen weiter, z. B. Kundenanfragen, Kundenmanagement-Anfragen, Technikerfragen, Materialfragen, Schulungsfragen, Personalfragen, Rechnungsfragen, Vertriebsanfragen, Wartungsanfragen.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sog. Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M33	<p>1. Management: Finance und High-Level-KPI (Dataflow-Diagramm als Blaupause zur Geschäftsstrategie)</p> <p>2. Asset-Management</p> <p>3. Data-Scientisten und -Scientistinnen</p> <p>4. Level-3-Support - braucht die Rückmeldung</p> <p>5. Level-2-Support auch O&M-Manager</p> <p>6. Asset-Integrity-Monitoring (neue Abteilung): Muss begreifen, welche Daten überhaupt erfasst werden und zu welchen Datenprodukten diese führen</p> <p>First-Level-Support - Surveillance-Center: eingeschränktes Aufgabengebiet, für sie wäre der Datenfluss relativ uninteressant > keine strategische Rolle, daher als Sicht nicht notwendig</p>	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <p>1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2.</p> <p>2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt.</p> <p>3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung.</p> <p>4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten.</p> <p>5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um.</p> <p>6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.</p>
	M4	Es gibt schon digitale Service- und Einsatzberichte, im nächsten Schritt müssen sie kombiniert werden.	05'	Es existieren Informationen zu Serviceaufträgen im Ticketsystem, zu Schichtübergaben, Service- und Einsatzberichten in Form von digitalen Daten. Zusätzlich wird eine Vielzahl manuell erstellter Listen verwendet.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M45	<p>Tabellarische Darstellung der Anforderungen an Reporting</p> <ul style="list-style-type: none"> - Level 1 – Echtzeit (Service-Management-System – Echtzeitdaten für aktuellen Stand Windturbine) - Level 2 – 12h-Vorplanung - Level 3 – 72h-Vorplanung - Asset-Management - Management 	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support - Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
	M46	<p>Kritisch prüfen: Haben wir alle Stakeholder? Wer ist noch beteiligt?</p>	03'	<p>In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restpunktlisten, die, je nach Kritikalität,</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
	M47	Die Materialwirtschaft liegt zwischen Level 2 und 3: Wenn es klar ist, welche Bauteile defekt sind, die bei der Einsatzplanung direkt berücksichtigt werden müssen, wird der Materialdistributionsprozesse gestartet	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>ISP der technische Support (Level 3) unterstützt den Level 1, dort wird noch einmal technisch geprüft, ob Fehler zurückgesetzt werden.</p> <p>Ordnung der drei Servicelevel wurde vor einiger Zeit schon korrigiert, um Kosten zu sparen. Es hat einen Vorteil, den Fehler durch den technischen Support zuerst bewerten zu lassen, dadurch wird die Einsatzplanung verbessert. Der technische Support bei Deutsche Windtechnik unterstützt dabei den Service-Level 1.</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Sicht des ISPs auf die drei Servicelevel:</p> <ul style="list-style-type: none"> ○ 1st Level: Leitwarte ○ 2nd Level: technischer Support (Fehler genauer beobachten/bewerten) ○ Level 3: Einsatzplanung 	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
	M5	<p>Die Entstörungsteams sind sogar besser ausgebildet. Es wird viel Wert daraufgelegt, dass die Teams qualifiziert sind (es gibt Trainingswochen und Schulungskampagnen).</p>	03'	<p>In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restpunktlisten, die, je nach Kritikalität,</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
		Die Entstörungsteams erledigen auch, was die geplante Wartung auf eine Restpunktliste schiebt (z. B. Defekte, die bei der geplanten Wartung entdeckt werden).	03'	In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restpunktlisten, die, je nach Kritikalität, anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
		Es gibt auch eine Fernentstörung über die Leitwarte.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <p>1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2.</p> <p>2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt.</p> <p>3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung.</p> <p>4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				<p>5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um.</p> <p>6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Es gibt eine Person im Engineering-Team, die sich um die Entstörungen kümmert. Es werden Entstöraufträge erstellt. Es finden wöchentlich Meetings statt, um zu entscheiden, wie die Entstörungen abgearbeitet werden.</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
		<p>Es gibt jeden Morgen ein Dashboard (Zeitung) über den Windpark, dort wird beschrieben, welchen Status jede WTG hat.</p>	<p>04'</p>	<p>Ein tägliches Dashboard gibt Übersicht über den Windpark (Wetter, Einspeisung), den Status einzelner Anlagen und aktuelle und vergangene Einsätze.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Es gibt Reserveteams, um kranke Mitarbeiter zu ersetzen.	03'	In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restepunktlisten, die, je nach Kritikalität, anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
		Es sind Entstörungsteams (v. a. im Winter) im Einsatz (ca. vier Teams sind geplant), die sich das anschauen und die Störungen abarbeiten	03'	In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restepunktlisten, die, je nach Kritikalität, anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
		Wartung: Optimierung durch ein Neun-Mann-Team in zwei Schichten an 5MW-Windenergieanlagen (Maschinenhaus, Rotorblatt, Turm, ...).	03'	In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restepunktlisten, die, je nach Kritikalität, anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M50	Parameter zur Bewertung der Daten (für einen Generatorfehler) werden durch Wissen von Expert*innen festgelegt	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
	M6	Die Prozesse können grob in Entstörung und geplante Wartung unterschieden werden	03'	<p>In der Betriebsführung und Instandhaltung gibt es einen Prozess für die Entstörung durch hochqualifizierte Entstörungsteams und einen für geplante Wartungen durch Instandhaltungsteams. Die Instandhaltungsteams führen Restpunktlisten, die, je nach Kritikalität,</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				anschließend von Wartungs- oder Entstörungsteams abgearbeitet werden.
	M7	Das Management überprüft die wichtigsten KPIs für die Windparks.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <p>1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2.</p> <p>2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt.</p> <p>3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung.</p> <p>4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten.</p> <p>5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um.</p> <p>6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Der Betreiber ist aufgeteilt in die Bau- und Entwicklungsorganisation sowie O&M.	01'	Bei Betreiberfirmen sind die Projektentwicklungsteams sowie die Betriebsführungs- und Instandhaltungsteams getrennt (Der Betrieb ist in Verwaltung und technische Betriebsführung gegliedert). Die technische Betriebsführung ist nach Fachbereichen aufgeteilt: z. B. Gründungsstrukturen, Windenergieanlagen und Datenanalyse.
		Die Abteilung für Anlagenintegrität ist weiter in <i>Unterabteilungen</i> unterteilt: Elektrik, Gründungsstrukturen, Windenergieanlagen und Datenanalyse (projektübergreifend).	01'	Bei Betreiberfirmen sind die Projektentwicklungsteams sowie die Betriebsführungs- und Instandhaltungsteams getrennt (Der Betrieb ist in Verwaltung und technische Betriebsführung gegliedert). Die technische Betriebsführung ist nach Fachbereichen aufgeteilt: z. B. Gründungsstrukturen, Windenergieanlagen und Datenanalyse.
		O&M gliedert sich in vier Unterabteilungen: Standorte, Joint Ventures, vertragliche und kommerzielle Dienstleistungen, Anlagenintegrität (für technische Bewertung, Überwachung usw.)	01'	Bei Betreiberfirmen sind die Projektentwicklungsteams sowie die Betriebsführungs- und Instandhaltungsteams getrennt (Der Betrieb ist in Verwaltung und technische Betriebsführung gegliedert). Die technische Betriebsführung ist nach Fachbereichen aufgeteilt: z. B. Gründungsstrukturen, Windenergieanlagen und Datenanalyse.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
	M9	<p>Basierend auf den Störmeldungen, die nicht von der Leitwarte zurückgesetzt werden können, werden die Technik und der Service aktiv.</p>	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Die Leitwarte bekommt alle Störungsnachrichten.	02'	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Die Leitwarte ist für den 1st-Level-Support zuständig und macht z. B. zuerst einen Reset, wenn möglich.</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. -Level-1 Support - Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		<p>Technik und Datenfernüberwachung sind vorgelagert zum Service – je besser hier die Vorarbeiten gemacht werden, umso besser läuft der Service.</p>	<p>02'</p>	<p>Die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks lässt sich wie folgt zusammenfassen:</p> <ol style="list-style-type: none"> 1. Level-1-Support – Die Leitwarte, mit einem hohen Bedarf an Echtzeitdaten, setzt möglichst viele Anlagenfehler durch sogenannte Fernwartung zurück, ggf. in Rücksprache mit Level 3 (siehe unten). Ist die Fernwartung nicht erfolgreich, wird ein Ticket für Level 2 (siehe unten) erstellt, um vor Ort zu entstören. Die Leitwarte hat einen Überblick über Arbeiten, die aktuell durchgeführt werden, und bekommt die Einsatzplanung von Level 2. 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant und führt Wartungs- und Instandhaltungsarbeiten durch. Sie priorisiert Offshore-Einsätze und fragt dafür Einsatzbedingungen vor Ort und Qualifikationen von Teams ab. Wo es nötig ist, wird die Materialbeschaffung involviert. Hier werden eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt, insbesondere mit Hinblick auf das Wetter. Es werden die Arbeitseinsätze koordiniert und durchgeführt. 3. Level 3 – Der technische Support besteht aus Spezialistinnen und Spezialisten für unterschiedliche Baugruppen und -teile und legt Parameter zur Datenbewertung fest. Der technische Support gibt Rückmeldungen, ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Alternativ werden Aufträge für die Instandhaltungen in Level 2 erstellt. Durch diese Abstimmung sinkt der Aufwand für Level 2. Der Datenbedarf liegt hier sowohl bei Vorhersagen für die nächsten 72 h als auch bei historischen Daten zur Fehleridentifikation und -behebung. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring – Backoffice-Team, das sich typischerweise um mehrere Assets kümmert und für die Weiterentwicklung der Datenanalyse zuständig ist, mit dem Ziel, den technischen Support zu verbessern. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
		<p>Wartungsplanung und Serviceplanung müssen unterschieden werden:</p> <ul style="list-style-type: none"> o Wartungsprotokolle fest definiert o Serviceprotokolle teilweise unvollständig oder 	<p>06'</p>	<p>Wartungsprotokolle sind fest definiert, während Serviceprotokolle unvollständig und uneinheitlich sein können.</p>

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		von der Qualität her so unterschiedlich, dass sie nicht verglichen werden können		
SW	M11	Wind-Turbine-Controller (WTC)-Events (Base-Viewer-Daten)	02'	Fehlermeldungen der Anlage werden über den Wind-Turbine-Controller (WTC) kommuniziert.
	M13	We-Flow wird genutzt, um Prozesse zu visualisieren.	05'	Prozess-Visualisierungssoftware wird verwendet, um die Prozesse bei einem Betreiber zu visualisieren.
	M19	Anfahrts- und Schlüsselinformationen liegen im Windparkordner oder in der DKV Fleetview Software vor	06'	Es existiert eine Software zum Flottenmanagement für die Servicefahrzeuge.
		Logbuch und 10min-Log der Anlagen (allgemeine Anlageninformationen)	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		RotorSoft (Logbuchpflege, Auswertungen, Berechnung Verfügbarkeit, Kontrolle Datenübertragung (unabhängig von Leitwarte) -> Livezugang)	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		RotorSoft/Betriebsführungssoftware, tägliche Arbeit in RotorSoft (Logbuchpflege, Auswertungen, Berechnung Verfügbarkeit Kontrolle Datenübertragung (unabhängig von Leitwarte) à Livezugang)	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		RotorSoft-Logbuch	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		RotorSoft-Logbuch für allgemeine Anlageninformationen	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
	M20	RotorSoft	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		SAP für Materialbestellungen	01'	ERP-Systeme werden zur Datenerfassung und Datenhaltung genutzt (Stammdaten, Servicereports, Materialbestellung).
	M33	Servicereports-Auszug aus SAP-System	01'	ERP-Systeme werden zur Datenerfassung und Datenhaltung genutzt (Stammdaten, Servicereports, Materialbestellung).
	M4	Betriebsführungssoftware von RotorSoft zur Anlagenüberwachung und zum Tracken des Anlagenhistorie	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		ERP/SAP-System als Stammdatensystem – zukünftig soll das Pro Alpha werden.	01'	ERP-Systeme werden zur Datenerfassung und Datenhaltung genutzt (Stammdaten, Service Reports, Materialbestellung).
		Service-Management-System zur Abwicklung von operativen Tätigkeiten läuft parallel	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
	M6	SAP wird für Datenhaltung zentral genutzt	01'	ERP-Systeme werden zur Datenerfassung und Datenhaltung genutzt (Stammdaten, Service Reports, Materialbestellung).
	M7	SAP-System zur Erfassung der Daten	01'	ERP-Systeme werden zur Datenerfassung und Datenhaltung genutzt (Stammdaten, Service Reports, Materialbestellung).
	M9	Es gibt RotorSoft, damit können Fehler standardisiert werden	03'	Service-Management-Systeme werden zur operativen Planung (Standardisierung von Fehlern, Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie etc.) eingesetzt.
		Messung des Verschleißes von Generatorbürsten (manuell über Tablets, L-mobile Software)	04'	Servicetechniker nutzen Tablets für das Dokumentieren von Vor-Ort-Prüfungen/-Messungen und Wartungsprotokollen.
V	M10	Gerade bei neuen Anlagen und Parks werden in allen Prozessen Datenprodukte genutzt, der Betreiber ist in der Datenerhebung involviert bzw. bekommt die Daten für die Datenprodukte	01'	Datenprodukte müssen klar definiert werden und können auch bei Verträgen für neue Windparks genutzt werden.
	M3	Glossar für die Definitionen notwendig	04'	Ein Glossar würde helfen, das in <i>WiSA Big Data</i> erarbeitete Evaluationsmodell besser zu verstehen.
	M33	Aktuelle Darstellung spiegelt wahre Situation wider (alles über O&M-Manager)	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Brüche in der Grafik wegen der Strings	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Die Filterung im Sankey-Diagramm sollte nicht nur nach dem Sunburst-Diagramm, sondern auch nach verschiedenen Kategorien möglich sein	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Farben z. B. nach der EN-Kategorie	02'	Die Visualisierung des Sankey-Diagramms sollte eingängig und übersichtlich ggf. durch Kategorien in verschiedenen Farben darstellen, auch wenn ein Filter gesetzt wird

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Gefilterte Kategorien in den einzelnen EN- Normen sollten auch farblich abgesetzt sein.	02'	Die Visualisierung des Sankey-Diagramms sollte eingängig und übersichtlich ggf. durch Kategorien in verschiedenen Farben darstellen, auch wenn ein Filter gesetzt wird
	M39	Die Datenproduktliste muss sich weiter konsolidieren.	07'	Die in <i>WiSA Big Data</i> erarbeitete Datenproduktliste muss konsolidiert werden.
		Vier Typen von Analysen: - Echtzeitanalysen (permanent) - Zeitlich vorgegebene Analysen - Event-getriggerte Analysen - On-demand-Analysen	06'	Vier Datenanalysetypen: - Echtzeit - Zeitlich vorgegeben - Event-getriggert - On demand/ ad hoc
	M40	Der Effort of Implementation sollte in folgende Unterpunkte gegliedert werden (Vorschlag Forschungspartner): 1. Aufwand der Datenaufbereitung 2. Umsetzung der Methodik 3. Hochaufgelöste Daten/ Fehlerfrüherkennung	08'	Der Implementierungsaufwand für Datenanalyse könnte in drei Unterpunkte aufgeteilt werden: 1. Datenaufbereitung (hochaufgelöste oder gemittelte Daten) 2. Methodenumsetzung 3. Analyse
	M41	Gleichgewichtung Forschung und Industrie - Priorität 1: Projektfokus - Priorität 2: restliche Datenprodukte	05'	Innerhalb von <i>WiSA</i> müssen Datenprodukte und zugehörige KPIs priorisiert werden, um den richtigen Fokus für die Data-Analysten sowie -analytinnen und die Anwendungsdomäne zu ermöglichen.
	M43	Datenprodukte müssen noch geschärft werden, von Seiten der Industrie wie auch der Forschung.	07'	Die in <i>WiSA Big Data</i> erarbeitete Datenproduktliste muss konsolidiert werden.
	M45	BMC-Ansatz hilft beim Verständnis der Datenprodukte.	09'	Das BMC hilft, Datenprodukte mit verschiedenen Stakeholdern zu kommunizieren.
	M46	Glossar/Begriffsverständnis für das Evaluationsmodell sollte einheitlich sein.	04'	Ein Glossar würde helfen, das in <i>WiSA Big Data</i> erarbeitete Evaluationsmodell besser zu verstehen.
		Schlüsselerkenntnis bei den Datenprodukten: Hier ist zu beachten, dass nicht zu generisch definiert wird.	01'	Datenprodukte müssen klar definiert werden und können auch bei Verträgen für neue Windparks genutzt werden.
	M47	Die Darstellung wird als zu komplex eingeschätzt, um sie schnell erfassen zu können.	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Die Gesamtübersicht ist recht unübersichtlich, da viele Fragestellungen aufgeführt sind.	02'	Die Visualisierung des Datenflusses über Sankey-Diagramme sollte eingängig und übersichtlich gestaltet werden, ggf. durch Kategorien in verschiedenen Farben, auch wenn ein Filter gesetzt wird.
		Die Gewichtung (Dicke der Sankey-Stränge) muss noch geklärt werden. Soll die Frage beantwortet werden: Welche Datenprodukte haben einen größeren Wert in Organisationen?	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
				Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Eine klare Definition, wie die Dicke der Stränge definiert ist, wird benötigt.	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Einführen eines definierten Color-Codes (Legende)	02'	Die Visualisierung des Datenflusses über Sankey-Diagramme sollte eingängig und übersichtlich gestaltet werden, ggf. durch Kategorien in verschiedenen Farben, auch wenn ein Filter gesetzt wird.
		Es hilft die Filterung durch die Untergruppen	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Verbale Erläuterungen helfen, aber der Weg zur Visualisierung erscheint unklar	03'	Innerhalb der Sankey-Visualisierung sollten optische Brüche vermieden werden. Filterfunktionen sollten für verschiedene Kategorien möglich und farblich abgesetzt sein. Andernfalls wird die Visualisierung schnell zu komplex. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
		Wichtig wäre die interne Priorisierung der einzelnen KPIs. Hier wahrscheinlich besonders die BI-Produkte wesentlich, da diese das Tagesgeschäft sogar mehr beeinflussen als die Predictive-Maintenance-Fragestellungen.	05'	Innerhalb von WiSA müssen Datenprodukte und zugehörige KPIs priorisiert werden, um den richtigen Fokus für die Data-Analysten sowie -analytinnen und die Anwendungsdomäne zu ermöglichen.
	M48	Nicht funktionale Anforderungen: - Frequenz, wann das Ergebnis benötigt wird - Schnittstellen - Welche Form von Datenbanken - Problem-Statement	10'	Nicht funktionale Anforderungen für das in WiSA Big Data erarbeitete Evaluationsmodell umfassen die Häufigkeit, wann Ergebnisse benötigt werden, die Schnittstellen, die Form der Datenbank und eine klare Definition, welches Problem gelöst werden soll.
	M51	Das BMC und die Diskussion haben die Datenprodukte mit Leben gefüllt. Es hat geholfen zu verstehen, wie die Datengrundlage aussieht und wo noch etwas fehlt.	09'	Das BMC hilft Datenprodukte mit verschiedenen Stakeholdern zu kommunizieren.
		Das Canvas hat sich als gute Basis zur Diskussion herausgestellt.	09'	Das BMC hilft Datenprodukte mit verschiedenen Stakeholdern zu kommunizieren.

Kategorie:	Meeting Id.	Paraphrase	R1	Reduktion (R1)
		Inhaltliche Ebene: Detaillierter über die Datenprodukte zu sprechen, hat Hürden genommen und ein besseres Verständnis geschaffen. Auch darüber, wo man mit den Methoden anknüpfen kann. Dass der Mehrwert von eher einfachen Datenprodukten hoch ist, ist ein Key-Takeaway.	09'	Das BMC hilft Datenprodukte mit verschiedenen Stakeholdern zu kommunizieren.

Tab.A.1 Ergebnisse Reduktion (R1)

C Ergebnisse Codierung Interviews mit Expert*innen (Runde 2)

Kategorie (neu):	R2	Reduktion (R2)
A	01''	<p>Wartungskampagnen erzeugen viele Datensätze. Die Daten können dabei strukturiert, semistrukturiert oder unstrukturiert, als gemittelte Werte oder in Echtzeit vorliegen. In der Zusammenarbeit mit Drittanbietern stellt Datensicherheit eine große Herausforderung für Datenaustausch dar.</p> <p>Neben den Windenergieanlagen (Sensordaten, Wartungshistorie inklusive getauschter Komponenten) existieren fest definierte Wartungsprotokolle für geplante Wartungen und Serviceprotokolle, die bei Entstörungen ausgefüllt werden und uneinheitlich sein können. Daneben bestehen zahlreiche lokale Listen zur Wissensvermittlung, um die Wartungsplanung durchzuführen. Die Wartungsprotokolle und Pläne geben Informationen über Aktivitäten vor Ort. Parallel ist ein Schichtblatt als Livedokument zur Protokollierung der Schicht geöffnet. Nach Abschluss der Schichten werden Feedback und Lessons Learned festgehalten und in regelmäßigen Feedbackrunden besprochen. In einem Jahresgespräch werden diese Lessons Learned in Tasks umgewandelt und anschließend bearbeitet, um z. B. Wartungsprozesse zu optimieren.</p>
	02''	<p>Bei einem der Betreiber gibt es eine tägliche Dashboard-Übersicht über den Windparkstatus und aktuell laufende Einsätze.</p> <p>Materiallisten dienen als Lebenslauf der Windenergieanlagen, sie geben an, welche Materialien bei der Betriebsführung und Instandhaltung von Anlagen verbraucht wurden. Häufig handelt es sich um Standardwartung, allerdings mit teils abweichenden Standardstücklisten. In einem Windpark-Ordner werden sämtliche parkspezifischen Informationen und Dokumente untergebracht.</p>
BMC	01''	Ein Glossar hilft, das Evaluationsmodell besser zu verstehen. Um Anforderungen der Data-Science und der Anwendungsdomäne zu verbinden, kann ein BMC verwendet werden. Das BMC hilft dabei, Datenprodukte zu konsolidieren, klar zu definieren und zu priorisieren. Es umfasst Informationen wie Häufigkeit der Nutzung von Datenprodukten, Schnittstellen und Definitionen.
DANA	01''	<p>Das Ziel der Betreiber ist es, mehr aus den Daten herauszuholen. Dies soll durch Data-Science-Ansätze erreicht werden. Damit können voraussichtlich neue Einsichten gewonnen und verbesserte Vorhersagen getroffen werden. Die notwendige Datenqualität ist von der Datenanalysemethode abhängig. Eine hohe Datenqualität reduziert den Implementierungsaufwand. Durch eigene Datenauswertungstools werden Teile der Livedaten ausgewertet.</p> <p>Der Implementierungsaufwand kann in die Datenaufbereitung, die Methodenumsetzung und die Analyse unterteilt werden. Bei den Datenanalysetypen kann zwischen Echtzeitanalysen zeitlich vorgegebenen, ereignisgesteuerten und bedarfsgesteuerten Ad-hoc-Analysen unterschieden werden.</p>
	02''	<p>Innerhalb des Forschungsprojektes stellen nicht alle Betreiber Livedaten zur Verfügung. Allerdings können große Mengen an Daten unterschiedlicher Systeme geteilt werden.</p> <p>Fehlermeldungen aus dem WTC-/SCADA-System können je nach System abweichen und werden von den Betreibern schon zum Teil für Vorhersagen genutzt. Allerdings ist zu berücksichtigen, dass Netzanforderungen zur Leistungsreduktion in Datenanalysen berücksichtigt werden müssen. Im Weiteren ist die Datenqualität schwer bewertbar, wenn der Betreiber die Inputdaten nicht kontrollieren kann (etwa da der Hersteller keinen Zugriff gewährt). Dies wird dadurch erschwert, dass eine Vielzahl von Datenkanälen (85–5000 je nach Anlagentyp) zur Fehleranalyse relevant sein können und Betreiber/ ISPs Auswertungen zum Teil über Excel oder eigene Tools durchführen, was zu Medienbrüchen führt.</p>
DM	01''	Datenmanagement und Data-Governance zur Definition von Rollen sind notwendig, um die Datenqualität langfristig zu verbessern. Das Datenmanagement kann zentralisiert in Form einer Datenbank oder eines Data-Warehouse ohne einen Data-Lake durchgeführt werden. Kompliziertes Datenmanagement ermöglicht es, Entscheidungen datengetrieben zu gestalten. Eine Priorität haben hierbei Daten, die noch digitalisiert werden müssen.
GE	01''	Eine Herausforderung besteht in den uneinheitlichen Bezeichnungen von Systemen und Komponenten. Im Weiteren sind einige Kosten, z. B. Hardwarekosten für Sensorik, nur durch Betreiber bzw. Hersteller bewertbar.

Kategorie (neu):	R2	Reduktion (R2)
		Ein Ziel des Evaluationsmodells ist es, manuelle Analysen zu identifizieren, die später automatisiert werden können.
KPI	01''	Generell kann in externe KPIs (bezogen auf vertragliche Vorgaben, etwa Strafzahlung bei Unterschreitung der Verfügbarkeit) und interne KPIs (leistungsbezogen, technisch oder organisatorisch) unterschieden werden. Die Verfügbarkeit mit ihren Ausprägungen (energetisch, umsatz- oder zeitbezogen) ist die relevanteste Kennzahl. Neben ihr gehört die <i>Leistung gemäß Nennleistungskurve</i> zu den leistungsbezogenen KPIs. Bei den technischen KPIs geht es zuerst darum, die Datenverbindung und den Status der Anlage zu analysieren. Ist dies sichergestellt, geht es vor allem um Fehleranalysen (Typ, Häufigkeit, Ausfallraten), Früherkennung und Bewertung der Auswirkung von Fehlern (etwa <i>Mean Time to Repair</i>) auf die Verfügbarkeit. Wenn eine Komponente getauscht werden muss, ist zu klären, ob ein Gewährleistungsanspruch besteht. Organisatorisch wird beispielsweise die Effizienz verschiedener Einsatzteams bewertet und verglichen oder es werden Gründe für <u>Verzögerungen in der Wartung</u> ausgewertet.
O	01''	Betreiber von Windparks sind unterschiedlich organisiert. Ein Betreiber des Konsortiums bildet die gesamte Wertschöpfungskette von der Projektentwicklung über die Anlagenentwicklung, die Fabrikation bis zur Installation und Betriebsführung und Instandhaltung ab. Ein weiterer Betreiber setzt auf Lieferanten für Anlagen und trennt auch intern seine Projektentwicklungsabteilung und die Betriebsführung und Instandhaltung, die technische Probleme mit den Anlagenlieferanten klärt. Eine besondere Herausforderung stellen dabei Windpark-Portfolios mit unterschiedlichen Windanlagentypen verschiedener Hersteller dar. Es ist daher von Bedeutung, vertragliche Pflichten und Ansprechpartner nachzuerfolgen.
R	01''	Eine Vielzahl interner und externer Stakeholder mit unterschiedlichen Hintergründen, Anforderungen und vertraglichen Rechten und Pflichten ist in der Betriebsführung und Instandhaltung zu berücksichtigen. Lastenhefte und Verträge sowie regelmäßige Status-Meetings regeln die Zusammenarbeit. Aufgrund personenbezogener Daten kann ein Datenaustausch schwierig sein. Daher ist es wesentlich Ansprechpartner*innen und Informationspflichten im Blick zu behalten.
	02''	Zusammengefasst besteht die Organisationsstruktur innerhalb der Betriebsführung und Instandhaltung eines Windparks aus: 1. Level-1-Support – Die Leitwarte greift auf Echtzeitdaten für Anlagenfehler zu. Möglichst viele davon werden durch Fernwartung, ggf. in Rücksprache mit Level 3 (siehe unten), zurückgesetzt. Ist dies nicht möglich, wird ein Entstörungsticket für Level 2 (siehe unten) erstellt. Die Leitwarte hat die Übersicht über aktuelle Arbeiten und die Einsatzplanung (von Level 2). 2. Level-2-Support – Die Arbeitsvorbereitung bzw. -ausführung plant, koordiniert und führt Wartungs- und Instandhaltungsarbeiten unter Berücksichtigung des Wetters und der Ressourcenverfügbarkeit durch. Es wird eine 12h-, 24h-, 48h- und 72h-Vorausplanung durchgeführt. 3. Level 3 – Der technische Support besteht aus technischen Spezialistinnen und Spezialisten für unterschiedliche Fachgebiete. Er legt Parameter zur Datenbewertung fest, etwa ob ein Fehler durch Fernwartung zurückgesetzt werden kann. Es werden 72h-Vorhersagen und historische Daten zur Fehleranalyse benötigt. 4. Data-Science/Data-Analysis oder Asset-Integrity-Monitoring kümmert sich um mehrere Assets und entwickelt die Datenanalyse für besseren technischen Support weiter. Der Datenbedarf liegt bei historischen Daten. 5. Asset-Management (für alle Windparks) setzt die Betriebsführungs- und Instandhaltungsstrategie des Managements um. 6. Management des Betreibers überprüft die wichtigsten KPIs und sorgt dafür, dass Gesetze und externe Vorgaben in die Strategie und das tägliche Arbeiten einfließen.
Sankey	01''	Die Visualisierung des Sankey-Diagramms ist eingängig und übersichtlich zu gestalten. So sollten verschiedene Kategorien farblich abgesetzt werden und filterbar sein. Optische Brüche sind zu vermeiden, um die Visualisierung nicht unnötig komplex zu machen. Die Visualisierungsschritte sollten so nachvollziehbar wie möglich sein.
SW	01''	Neben einem ERP-System zur Stammdatenerfassung und -pflege steht ein Service-Management-System zur operativen Planung zur Verfügung (Logbuchpflege, Verfügbarkeitsberechnung, Anlagenhistorie). Dieses Standard-Setup kann durch Flottenmanagement- oder Prozessvisualisierungssoftware ergänzt werden.

Tab.B.1 Ergebnisse Reduktion (R1)

D Codierleitfaden Datenwertschöpfungsketten Ontologie

	Kategorie	Kernfragen zum Datenprodukt	Ausprägungen
Datenproduktnutzung	KB: Kundenbeziehung In welcher Beziehung steht die Kundschaft, hier die Organisation bzw. die Anwendenden, zum Datenprodukt? In welchem Prozess(schritt) wird es von wem angewandt?	KB1: Beziehung Datenprodukt <> Beteiligte?	Feedbackloop zwischen den Beteiligten. Iterative Optimierung/Erfolgsmessung und Qualitätssicherung.
		KB2: Relevanter Prozessschritt für das Datenprodukt?	Freitext nach der Prozesslandkarte
		KB3: Akzeptanzkriterien für das Ergebnis?	Relevanz, Genauigkeit, Vollständigkeit, Rechtzeitigkeit – BVI
	VK: Vertriebskanäle In welchem Format und welcher Frequenz wird das Datenprodukt final kommuniziert?	VK1: Frequenz der Nutzung?	[M, h, d, m, ad hoc]
		VK2: Gebrauchsform Datenprodukt?	KPI, Dashboards, Reports, E-Mail
		VK3: Visualisierung?	Tabelle, Kurvendiagramm, Balken-/ Tortendiagramme, Ampel/Tacho, Scatter
	ZG: Zielgruppen Wer soll das Datenprodukt innerhalb der Organisation nutzen?	ZG1: Wer wird informiert? Wem hilft das Datenproduktes?	(I) Informed: Level 1, Level 2, Level 3, Management, Asset-Management, Data-Science team -> Verknüpfung zu ZG4
		ZG2: Wer entscheidet? Wer sind die Endanwendenden?	(R) Responsible – Verantwortlich für die Entscheidung: Level 1, Level 2, Level 3, Management, Asset-Management, Data-Scientisten und -Scientistinnen
		ZG3: Anwenderbericht – Wer macht was?	Als ... [wer] möchte ich ... [was] wissen, um ... zu entscheiden [warum] (vgl. Cohn 2004, S. 81).
	Wert	WS: Wertschöpfung (Value Proposition) Welchen Wert hat das Datenprodukt (potenziell)?	WS1: Welchen Wert hat diese Entscheidung monetär?
WS2: Welche Entscheidung verbessert/ermöglicht das Datenprodukt?			Freitext
WS3: Anforderung (nicht funktional)			Freitext
Datenproduktvorbereitung	SA: Schlüsselaktivitäten Welche Aktivitäten müssen, <i>intern</i> innerhalb der Datenauswertung und Datenprodukterstellung ausgeführt werden? -> Data-Science Canvas und Data-Science Workflow	SA1: Problem Statement (Anforderungsprofil)	Freitext
		SA3: Datenanalysemethoden und Modellauswahl	Klassifizierung Methodenübersicht RAM Modelltyp physikalisch - Blackbox
		SA2: Datenerfassung (Wie)?	Datenerfassung, Datenmanagement, ggf. Hardware-Procurement
		SA5: Modellaufbau (Trainieren, Testen)?	Welche KPIs werden betrachtet?
		SA4: Daten-Vorbereitung?	Codierung, Regression, Clustering
		SA6: Datenanalyse und Ergebnis (KPIs)?	Nach KPI-Datenbank
	SR: Schlüsselressourcen Was ist notwendig, um das Datenprodukt aufzusetzen und kontinuierlich bereitzustellen sowie zu nutzen?	SR1: Erforderliche Ressourcen?	Freitext
		SR2: Datenquellen?	Sensoren (SCADA, CMS, SHM), Audio und Video, Reports und Text, Logfiles, Web und Social, PPS (Produktionsplanungssoftw.), CRM (Customer-Relationship-Management), ERP (Enterprise-Resource-Planning)
		SR3: Beeinflussende Randbedingungen?	Freitext
	SP: Schlüsselpartner Welche Partner wirken bei der Erarbeitung und der	SP1: Interne und externe Partner?	Freitext
SP2: Wie wird unterstützt?		Datenerfassung, Datenvorbereitung, Datenanalyse, Datenmanagement	

	kontinuierlichen Bereitstellung mit?	SP3: Wie ist die Rolle des Partners im Data-Science-Team (z. B. Data Product Owner)?	Rollen im Data-Science-Team
Kosten	KS: Kostenstruktur Welche Kosten sind mit der Bereitstellung des Datenproduktes verbunden?	KS1: Wie hoch sind die Kosten/der Aufwand, um das Analyseergebnis des Data-Products zu generieren? (inkl. CAPEX für Messgeräte z. B.)	Freitext (€), Impactfactor
		KS2: Risiken	FMECA
Einkommen	EQ: Einkommensquellen (Nutzen) Welcher Nutzen kann aus der Anwendung des Datenproduktes gezogen werden? Wie ist dieser zu bewerten?	EQ1: Welches Einkommen/Kosteneinsparungen können durch das Data-Product erreicht werden?	Freitext
		EQ2: Data-Value	Monetär vs. BVI
Anwendung	PR: Prozesse Wie sieht der Prozess zur Generierung und Anwendung des Datenproduktes aus?	PR1: Muss ein neuer Prozess definiert werden oder wird es in einen bestehenden Prozess eingebunden?	Ja/Nein + Freitext
		PR2: Gibt es Alternativprozesse, um die Entscheidung zu treffen?	Ja/Nein + Freitext

Tab. C.1: Codierleitfaden

E Datenprodukttablelle

Skalierung Offshore:

Farbe	Relevanz	Kosten	Color	Relevance	Cost
3	Sehr wichtig	150.000,00 €	3	Very important	150.000,00 €
2,5	Wichtig	100.000,00 €	2,5	Important	100.000,00 €
2	Weniger wichtig	50.000,00 €	2	Less important	50.000,00 €
1,5	Kaum wichtig	25.000,00 €	1,5	Barely important	25.000,00 €
1	Unwichtig	7.500,00 €	1	Unimportant	7.500,00 €

Farbe	Genauigkeit	Kosten	Color	Accuracy	Cost
3	Sehr genau	150.000,00 €	3	Very Accurate	150.000,00 €
2,5	Genau	100.000,00 €	2,5	Exactly	100.000,00 €
2	Keine Angaben	50.000,00 €	2	No indication	50.000,00 €
1,5	Ungenau	25.000,00 €	1,5	Inaccurate	25.000,00 €
1	Sehr ungenau	7.500,00 €	1	Very inaccurate	7.500,00 €

Farbe	Rechtzeitigkeit	Kosten	Color	Timeliness	Cost
3	Rechtzeitig	100.000,00 €	3	On time	100.000,00 €
2	Verspätet	50.000,00 €	2	Late	50.000,00 €
1	Zu spät	7.500,00 €	1	Too late	7.500,00 €

Farbe	Wie oft (benötigt)?	Kosten	Color	Frequency of Usage	Cost
3	Stündlich/ Ad hoc	150.000,00 €	3	Hourly/ Ad hoc	150.000,00 €
2,5	Täglich	100.000,00 €	2,5	Daily	100.000,00 €
2	Wöchentlich	50.000,00 €	2	Weekly	50.000,00 €
1,5	Monatlich	25.000,00 €	1,5	Monthly	25.000,00 €
1	Jährlich	7.500,00 €	1	Yearly	7.500,00 €

Farbe	Vollständigkeit	Kosten	Color	Completeness	Cost
3	Vollständig	100.000,00 €	3	Completely	100.000,00 €
2	Teilweise vollständig	50.000,00 €	2	Partially complete	50.000,00 €
1	Unvollständig	7.500,00 €	1	Incomplete	7.500,00 €

Farbe	Kosten _{DAO}	Color	Cost _{DAO} scaled
1	150.000,00 €	1	150.000,00 €
1,5	100.000,00 €	1,5	100.000,00 €
2	50.000,00 €	2	50.000,00 €
2,5	25.000,00 €	2,5	25.000,00 €
3	7.500,00 €	3	7.500,00 €

Farbe	Kosten _{DEC}	Color	Cost _{DEC} scaled
1	150.000,00 €	1	150.000,00 €
1,5	100.000,00 €	1,5	100.000,00 €
2	50.000,00 €	2	50.000,00 €
2,5	25.000,00 €	2,5	25.000,00 €
3	7.500,00 €	3	7.500,00 €

Skalierung Onshore:

Farbe	Relevanz	Kosten	Color	Relevance	Cost
3	Sehr wichtig	33.000,00 €	3	Very important	33.000,00 €
2,5	Wichtig	17.000,00 €	2,5	Important	17.000,00 €
2	Weniger wichtig	8.000,00 €	2	Less important	8.000,00 €
1,5	Kaum wichtig	2.500,00 €	1,5	Barely important	2.500,00 €
1	Unwichtig	1.500,00 €	1	Unimportant	1.500,00 €

Farbe	Genauigkeit	Kosten	Color	Accuracy	Cost
3	Sehr genau	33.000,00 €	3	Very Accurate	33.000,00 €
2,5	Genau	17.000,00 €	2,5	Exactly	17.000,00 €
2	Keine Angaben	8.000,00 €	2	No indication	8.000,00 €
1,5	Ungenau	2.500,00 €	1,5	Inaccurate	2.500,00 €
1	Sehr ungenau	1.500,00 €	1	Very inaccurate	1.500,00 €

Farbe	Rechtzeitigkeit	Kosten	Color	Timeliness	Cost
3	Rechtzeitig	33.000,00 €	3	On time	33.000,00 €
2	Verspätet	17.000,00 €	2	Late	17.000,00 €
1	Zu spät	2.500,00 €	1	Too late	2.500,00 €

Farbe	Wie oft (benötigt)?	Kosten	Color	Frequency of Usage	Cost
3	Stündlich/ Ad hoc	33.000,00 €	3	Hourly/ Ad hoc	33.000,00 €
2,5	Täglich	17.000,00 €	2,5	Daily	17.000,00 €
2	Wöchentlich	8.000,00 €	2	Weekly	8.000,00 €
1,5	Monatlich	2.500,00 €	1,5	Monthly	2.500,00 €
1	Jährlich	1.500,00 €	1	Yearly	1.500,00 €

Farbe	Vollständigkeit	Kosten	Color	Completeness	Cost
3	Vollständig	33.000,00 €	3	Completely	33.000,00 €
2	Teilweise vollständig	17.000,00 €	2	Partially complete	17.000,00 €
1	Unvollständig	2.500,00 €	1	Incomplete	2.500,00 €

Farbe	Kosten _{DAO}	Color	Cost _{DAO scaled}
1	33.000,00 €	1	33.000,00 €
1,5	17.000,00 €	1,5	17.000,00 €
2	8.000,00 €	2	8.000,00 €
2,5	2.500,00 €	2,5	2.500,00 €
3	1.500,00 €	3	1.500,00 €

Farbe	Kosten _{DEC}	Color	Cost _{DEC scaled}
1	33.000,00 €	1	33.000,00 €
1,5	17.000,00 €	1,5	17.000,00 €
2	8.000,00 €	2	8.000,00 €
2,5	2.500,00 €	2,5	2.500,00 €
3	1.500,00 €	3	1.500,00 €

Farbe	Integrität	Kosten	Color	Integrity	Cost
3	Es gibt klar geregelte Rol	33.000,00 €	3	There are clearly regulat	33.000,00 €
2	Es gibt grundlegende Reg	17.000,00 €	2	There are basic regulatio	17.000,00 €
1	Es gibt keinerlei Regeln	2.500,00 €	1	There are no regulations	2.500,00 €

Farbe	Konsistenz	Kosten	Color	Consistency	Cost
3	Die Daten sind an eindeu	33.000,00 €	3	Data is stored completel	33.000,00 €
2,5	Daten finden sich überw	17.000,00 €	2,5	Data is predominantl	17.000,00 €
2	Daten liegen sowohl une	8.000,00 €	2	Data is found both incon	8.000,00 €
1,5	Daten finden sich überw	2.500,00 €	1,5	Data is predominantl	2.500,00 €
1	Daten finden sich unein	1.500,00 €	1	Data is found inconsiste	1.500,00 €

Farbe	Kosten _{DAGO}	Color	Cost _{DAGO scaled}
1	33.000,00 €	3	33.000,00 €
1,5	17.000,00 €	2,5	17.000,00 €
2	8.000,00 €	2	8.000,00 €
2,5	2.500,00 €	1,5	2.500,00 €
3	1.500,00 €	1	1.500,00 €

Farbe	Zugänglichkeit	Kosten	Color	Accessibility	Cost
3	Es besteht vollständiger	33.000,00 €	3	There is full access to all	33.000,00 €
2,5	Es besteht größtenteils	17.000,00 €	2,5	There is mostly access to	17.000,00 €
2	Keine Daten	8.000,00 €	2	No data	8.000,00 €
1,5	Auf die Daten kann teilw	2.500,00 €	1,5	The data can be partially	2.500,00 €
1	Auf die Daten kann nicht	1.500,00 €	1	The data cannot be acce	1.500,00 €

Farbe	Glaubwürdigkeit	Kosten	Color	Credibility	Cost
3	Den Daten kann voll ver	33.000,00 €	3	The data can be fully tru	33.000,00 €
2,5	Den Daten kann überwie	17.000,00 €	2,5	The data can be predom	17.000,00 €
2	Keine Angaben	8.000,00 €	2	No data	8.000,00 €
1,5	Den Daten kann teilweis	2.500,00 €	1,5	The data can be partiall	2.500,00 €
1	Den Daten kann nicht ve	1.500,00 €	1	The data cannot be trust	1.500,00 €

Farbe	Interpretierbarkeit	Kosten	Color	Interpretability	Cost
3	Die Daten sind vollstän	33.000,00 €	3	The data are fully compr	33.000,00 €
2,5	Die Daten sind größtent	17.000,00 €	2,5	The data are mostly und	17.000,00 €
2	Keine Daten	8.000,00 €	2	No data	8.000,00 €
1,5	Die Daten sind teilweise	2.500,00 €	1,5	The data is partially und	2.500,00 €
1	Die Daten sind unverstär	1.500,00 €	1	The data are incompre	1.500,00 €

Farbe	Kosten _{DAMA}	Color	Cost _{DAMA scaled}
1	33.000,00 €	3	33.000,00 €
1,5	17.000,00 €	2,5	17.000,00 €
2	8.000,00 €	2	8.000,00 €
2,5	2.500,00 €	1,5	2.500,00 €
3	1.500,00 €	1	1.500,00 €

Skalierung der Nutzwertanalyse:

Wertschöpfung				Implementierungsaufwand			
Evaluation DWT	Evaluation VAT	Evaluation OBE	Existierened vs gewünscht	Daten-vorbereitung	Einfache Statistik	Aufwand Methoik	Projekt Fokus
20%	20%	20%	10%	20%	20%	20%	40%

ID	Question	Decision	EN Category	EN Sub-Category	KPI	KPI Detail
DWT02	Welche Anlagen sind besonders auffällig?	An welchen Anlagentypen treten welche Fehler vermehrt auf, so dass Aktionen geplant werden und erfolgen können.	Maintenance Engineering	Preventive Maintenance	Problemanlagen	Vorhanden
DWT05	Welche Bauteile wurden überdurchschnittlich häufig verbraucht?	Welche Bauteile müssen stärker ausgetauscht werden, wo besteht erhöhter Verschleiß und Handlungsbedarf	Maintenance Engineering	Preventive Maintenance	Number of used parts compared to average	Vorhanden
DWT07	Welche Mängel gibt es an der Anlage?	Können Mängel bei anstehenden Arbeiten oder Fehlereinsätzen mit abgearbeitet werden?	Maintenance Engineering	Preventive Maintenance	List of faults on turbine	Vorhanden
DWT09	Wie ist der aktuelle Abarbeitungsstand (Nachweise)?	Das Resultat aus Zeile 9, damit im Nachhinein rekapituliert werden kann, ob Fehler aus vergangenen Arbeiten entstanden sein können	Organization & Support	Productivity Effectiveness	Abarbeitungsstand	Erwünscht
DWT18	Welches Material könnte benötigt werden?		Administration & Supply	Materials & Spare parts	Benötigte Materialien	Erwünscht
DWT32	Ist der Fehler schon häufiger aufgetreten?	Welche Fehler treten wiederholt auf?	Maintenance Engineering	Durability	Fehlerhäufigkeit	Erwünscht
DWT33	Welche Fehlermeldungen treten besonders häufig auf?	Serviceplanung Fehlersuche	Maintenance Engineering	Preventive Maintenance	Servicebericht - WEA-Fehlermeldung	Vorhanden
DWT35	Welche Umrichterfehler kommen am häufigsten vor?	Informationen zur Entstehung durch die Leitwarte und vorgehende Fehlersuche	Maintenance Engineering	Preventive Maintenance	Umrichterfehlerarten (gesamt)	Erwünscht
DWT36	Welche Umrichterfehler kommen an einzelnen Anlagentypen am häufigsten vor?	Informationen zur Entstehung durch die Leitwarte und vorgehende Fehlersuche	Maintenance Engineering	Preventive Maintenance	Umrichterfehlerarten (gesamt)	Erwünscht
DWT58	Performt die Anlage gemäß Nennleistungskurve, etc.?	Welche korrigierenden Maßnahmen müssen bei Abweichung von der Nennleistungskurve (unter vorheriger Berücksichtigung möglicher Abweichungen aufgrund von Schallreduzierung nachts, Anlagendrosselungen durch EVU/DV,...) getroffen werden?	Maintenance Management	Technical Assessment	Anlagenperformance (bezogen auf Nennleistungskurve) [See also VAT01]	Vorhanden
DWT64	Welche WEA steht?	Reset versuch -> nicht erfolgreich -> weiterleiten an die Technik -> kein Erfolg, Einsatz einplanen	Maintenance Management	Technical Assessment	WEA status (aktiv, inaktiv)	Vorhanden
DWT65	Aufgrund welches Fehlers steht die WEA?	Reset versuch -> nicht erfolgreich -> weiterleiten an die Technik -> kein Erfolg, Einsatz einplanen	Maintenance Management	Technical Assessment	WEA status (aktiv, inaktiv)	Vorhanden
DWT66	Wo steht die WEA, wer ist am schnellsten da und kennt der T. sich mit dem WEA-Typ/Fehler aus		Maintenance Engineering	Preventive Maintenance	Ad-Hoc Entstörung	Erwünscht
DWT67	Um welchen Schaden handelt es sich?	Einsatzplanung	Maintenance Engineering	Preventive Maintenance	Schadensfall Groko	Vorhanden

ID	Question	Decision	EN Category	EN Sub-Category	KPI	KPI Detail
VAT01	Is the turbine operating within the nominal range?	Is there an issue with the turbine controller settings?	Maintenance	Capacity Effectiveness Integrity	WTG performance (based on nominal power curve) [See also DWT58]	Desired
VAT03	Is a blade operating with a slightly different pitch angle and inducing additional loads into the turbine and losing power?	Maintenance to correct pitch system	Maintenance Engineering	Capability & Criticality	Pitch angle misalignment	Desired
VAT04	How often does a specific system/component fail? Calculation should be done that a statistical valid and trustworthy number results.	Do I have a serial damage / failure? Is a specific component error prone and I need to adjust maintenance plans?	Maintenance Engineering	Durability	Failure rate	Desired
VAT05	Is the turbine operating in the correct IEC category ?	nein	Maintenance	Capacity Effectiveness Integrity	Operating Mode check	Desired
VAT06	Are there any unusual/abnormal outliers / behaviour changes detectable in the time series, e.g. temperature jumps or developments over time	Sensor or system / component should be checked	Maintenance	Capacity Effectiveness Integrity	Time series outlier detection	Desired
VAT12	Can I extend the operation of a specific component over the expected lifetime?	Is the operation of the asset extended? Do I need to exchange a component before the expected end of life?	Maintenance Engineering	Durability	Damage Equivalent loads / Load cycles	Desired
OBE01	Wird der Generator in den nächsten Tagen/Wochen einen Fehler verursachen, welcher zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) mit Hinblick auf die Rüst/ Vorlaufzeiten	Maintenance Engineering	Preventive Maintenance	Time To Failure Prediction	Desired
OBE02	Wird das Getriebe in den nächsten Tagen/Wochen einen Fehler verursachen, welcher zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) mit Hinblick auf die Rüst/ Vorlaufzeiten	Maintenance Engineering	Preventive Maintenance	Time To Failure Prediction	Desired
OBE03	Wird das Hauptlager in den nächsten Tagen/Wochen einen Fehler verursachen, welcher zu einem Wartungseinsatz führt?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) mit Hinblick auf die Rüst/ Vorlaufzeiten	Maintenance Engineering	Preventive Maintenance	Time To Failure Prediction	Desired
OBE04	Bestehen aktuell Fehlermuster an einer der Komponenten, welche einen kommenden Einsatz vermuten lassen?	Rechtzeitige Wartungsplanung (Entstörungsteam oder Großkomponententausch) mit Hinblick auf die Rüst/ Vorlaufzeiten	Maintenance Engineering	Preventive Maintenance	Fehlermuster/indikator	Desired
OBE05	Wie verhalten sich die 10minuten Statistiken im vergleich zu den hochaufgelösten Daten, u.A. : ist die annahme einer Normalverteilung legitim?	Bedarfsbezogene Einzelfallanalyse z.B. Serienfehler, Root cause Analysis Großkomponententausch	Maintenance Management	Technical Assessment	Abgleich 10-min Statistiken zu Hochaufgelösten Daten	Desired
OBE06	Statistik zu Einsätzen	Nachbetrachtung der Einsatzplanung um Muster zu identifizieren zur Planungsoptimierung und Kostenreduktion. Lernkurven effekte z.B. Bedarf an Großkomponenten e.g. verbesserte Planung der Materialwirtschaft.	Organization & Support	Productivity Effectiveness	Statistik zu Einsätzen	Exists

ID	Completeness	Accuracy	One time cost	Yearly costs	RoIDAQ	Integrity	Consistency	One time cost	Yearly cost	RoIDAGO	Data Governance
DWT02	Unvollständig	Ungenau	8.000 €	2.500 €	48%	Es gibt klar geregelte Rollen, Verantwortlichkeiten und Zugriffsrechte für Daten	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	1.500 €	17.000 €	184%	Technik
DWT05	Teilweise vollständig	Ungenau	1.500 €	8.000 €	205%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend uneinheitlich an verschiedenen Speicherorten	1.500 €	8.000 €	205%	Technik
DWT07	Teilweise vollständig	Genau	8.000 €	17.000 €	136%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	2.500 €	8.000 €	324%	Service
DWT09	Vollständig	Sehr genau	2.500 €	8.000 €	629%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	2.500 €	8.000 €	324%	Service
DWT18	Teilweise vollständig	Genau	1.500 €	17.000 €	184%	Es gibt grundlegende Regelungen	Daten liegen sowohl uneinheitlich und einheitlich vor	1.500 €	2.500 €	62,5%	Service
DWT32	Teilweise vollständig	Keine Angaben	1.500 €	8.000 €	263%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	1.500 €	8.000 €	358%	Leitwarte
DWT33	Unvollständig	Ungenau	1.500 €	8.000 €	53%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	2.500 €	17.000 €	174%	Leitwarte
DWT35	Unvollständig	Ungenau	8.000 €	8.000 €	31%	Es gibt grundlegende Regelungen	Daten liegen sowohl uneinheitlich und einheitlich vor	2.500 €	8.000 €	238%	Technik
DWT36	Teilweise vollständig	Ungenau	8.000 €	17.000 €	78%	Es gibt grundlegende Regelungen	Daten liegen sowohl uneinheitlich und einheitlich vor	2.500 €	17.000 €	128%	Technik
DWT58	Vollständig	Sehr genau	8.000 €	8.000 €	413%	Es gibt klar geregelte Rollen, Verantwortlichkeiten und Zugriffsrechte für Daten	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	8.000 €	8.000 €	313%	TBF
DWT64	Teilweise vollständig	Genau	8.000 €	2.500 €	324%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	8.000 €	8.000 €	213%	Leitwarte
DWT65	Vollständig	Genau	8.000 €	8.000 €	313%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	2.500 €	8.000 €	324%	Leitwarte
DWT66	Teilweise vollständig	Genau	2.500 €	17.000 €	174%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend einheitlich an verschiedenen Speicherorten	1.500 €	8.000 €	358%	Service
DWT67	Teilweise vollständig	Genau	1.500 €	33.000 €	99%	Es gibt grundlegende Regelungen	Daten finden sich überwiegend uneinheitlich an verschiedenen Speicherorten	2.500 €	8.000 €	186%	GroKo

ID	Completeness	Accuracy	One time costs	Yearly costs	RoIDAQ	Integrity	Consistency	One time cost DAGO	Yearly cost DAGO	RoIDAGO	Data Governance
VAT01	Partially complete	No indication	50.000 €	25.000 €	133%						
VAT03	Partially complete	No indication	50.000 €	25.000 €	133%						
VAT04	Completely	Very Accurate	7.500 €	50.000 €	435%						
VAT05	Partially complete	Exactly	25.000 €	7.500 €	462%						
VAT06	Partially complete	Inaccurate	100.000 €	50.000 €	50%						
VAT12	Partially complete	Exactly	50.000 €	7.500 €	261%						
OBE01	Teilweise vollständig	Keine Angaben	25.000 €	7.500 €	308%						
OBE02	Teilweise vollständig	Keine Angaben	25.000 €	7.500 €	308%						
OBE03	Teilweise vollständig	Keine Angaben	25.000 €	7.500 €	308%						
OBE04	Vollständig	Genau	7.500 €	7.500 €	1333%						
OBE05	Vollständig	Sehr genau	25.000 €	7.500 €	769%						
OBE06	Vollständig	Sehr genau	7.500 €	7.500 €	1667%						

ID	Accessibility	Credibility	Interpretability	One time cost DAMA	Yearly cost DAMA	RoIDAMA	Data Management Software	Evaluation DWT	Evaluation VAT	Evaluation OBE	Existing (1) vs wished (2)	Rating research	Effort data preparation	Possible quick wins with simple statistics on the	Effort method implementation	Project focus according to question	Total value added	Total implementation effort	RoIDANA
DWT02	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegend vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	33.000 €	96%	Rotorsoft	✓	○	✗	○		✓	✗	✗		1,7	1,0	170%
DWT05	Auf die Daten kann teilweise zugegriffen werden	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	17.000 €	125%	SAP	✓	○	✗	○					✗	1,7	0,4	425%
DWT07	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	17.000€	174%	Rotorsoft	✓	✓	✗	✓	○		✗	✗	✓	2,2	2,0	110%
DWT09	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind vollständig nachvollziehbar	2.500 €	8.000 €	425%	Local stored tables	✓	○	○	✗		○		✗	✓	1,5	0,8	188%
DWT18	Es besteht größtenteils Zugang zu den Daten	Keine Angaben	Die Daten sind teilweise verständlich	2.500 €	8.000 €	175%	Rotorsoft	✓	✓	○	✗				✗	✓	1,7	0,4	425%
DWT32	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	8.000 €	324%	Local stored tables	✓	○	○	○	○	✓	✗	✓		1,8	2,4	75%
DWT33	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	8.000 €	8.000 €	213%	Rotorsoft	✓	○	○	✗	○		✓			2,1	0,6	350%
DWT35	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	8.000 €	8.000 €	213%	Rotorsoft	✓	○	○	○		✓		✗	✓	1,8	1,0	180%
DWT3	Keine Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	8.000 €	8.000 €	175%	Rotorsoft	✓	○	○	○		✓		✗	✓	1,8	1,0	180%
DWT58	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	8.000 €	8.000 €	213%	Rotorsoft	✓	✓	✗	✓	○		✗	○	✓	2,2	2,2	100%
DWT64	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	17.000 €	174%	Rotorsoft	✓	✓	✗	✓		✓		✗	✓	2,2	1,0	220%
DWT65	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	17.000 €	174%	Rotorsoft	✓	✓	✗	✓	○		✗	✗	✓	2,2	2,0	110%
DWT66	Es besteht größtenteils Zugang zu den Daten	Den Daten kann voll vertraut werden	Die Daten sind größtenteils verständlich	8.000 €	8.000 €	279%	Not available	✓	○	○	✗				✗	✓	1,5	0,4	375%
DWT67	Es besteht größtenteils Zugang zu den Daten	Den Daten kann überwiegen d vertraut werden	Die Daten sind größtenteils verständlich	2.500 €	17.000 €	174%	Local stored tables	○	○	✗	✓	○	✓	✓	✗	✓	1,8	2,4	75%

	OBE06	OBE05	OBE04	OBE03	OBE02	OBE01	VAT12	VAT06	VAT05	VAT04	VAT03	VAT01	ID
													Accessibility
													Credibility
													Interpretability
													One time cost DAMA
													Yearly cost 890.894 DAMA
													RoIDAMA
													Data Management Software
	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	Evaluation DWT
							👍	👍	👍	👍	👍	👍	Evaluation VAT
											👍	👍	Evaluation OBE
	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	Existing (1) vs wished (2)
	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	👍	Rating research
													Effort data preparation
	👍	👎	👎	👎	👎	👎	👎	👍	👍	👍	👎	👎	Possible quick wins with simple statistics on the data (priority AP2).
		👍	👎	👎	👎	👎					👎	👍	Effort method implementation
	👎	👍	👍	👍	👍	👍	👎	👍	👎	👎	👍	👍	Project focus according to question
	1,4	1,7	1,7	1,5	1,5	1,5	2,1	2,3	2,1	1,8	2,7	2,7	Total value added
	1,0	2,6	2,0	2,0	2,0	2,0	0,6	2,2	1,0	0,8	2,0	2,2	Total implementation effort
	140%	65%	85%	75%	75%	75%	350%	105%	210%	225%	135%	123%	RoIDAMA

ID	Adressee	Protocol	Sensors (SHM/SMS/SCADA)	Tables	Audio & Video / Image material	Dashboard	SAP (Enterprise Resource Planning (ERP))	Rotorsoft (PPS)	Web & Social	Log files	CRM	Text	Others	Statistics from TS	Averaging	Filters	Trend analysis	Comparison to reference	Difference Δ	Distribution fit	Machine Learning	Regression	Clustering	Blackbox	Manuell	Software Tool	Visualisation	Format of Usage
DWT02	Leitwarte, Technik, Service		X							X															X			
DWT05	MaWi/ Technik/Service			X				X	X								X									L-Mobile	nicht vorhanden	Tabelle
DWT07	Technik/ Dispo/TBF			X	X																				X	L-Mobile		Tabelle
DWT09	Technik/ Dispo/TBF				X											X									X			
DWT18	Technik, Service, Lager		X	X	X									X											X			
DWT32	Leitwarte / Technik	X			X											X									X			
DWT33	Technik / Service			X	X									X											X	Rotorsoft		Tabelle
DWT35	Leitwarte, Technik, Service		X										X			X									X		Dash-board	
DWT36	Leitwarte/ Technik /TBF		X										X												X		Dash-board	
DWT58	TBF, Service, Technik/Engineering und Kunde (I)						X																		X	Rotorsoft		Kennlinien-diagramm
DWT64	Technischer Support, Leitwarte, Service, Vertrieb, Kundenmanagement			X										X	X											Software: Umrichter, Anlagensteuerung	Number / Text	Email
DWT65	Technischer Support, Leitwarte, Service, Vertrieb, Kundenmanagement			X										X	X											Software: Umrichter, Anlagensteuerung	Number / Text	Email
DWT66	Technik, Service, Lager				X								X												X			
DWT67	Technics/ Engineering, Service											X		X											X	Excel	Number / Text	Tabelle


ID	Addressee	Protocol	Sensors (SHM/SMS/SCADA)	Tables	Audio & Video / Image material	Dashboard	SAP (Enterprise Ressource Planning (ERP))	Rotorsoft (PPS)	Web & Social	Log files	CRM	Text	Others	Statistics from TS	Averaging	Filters	Trend analysis	Comparison to reference	Difference Δ	Distribution fit	Machine Learning	Regression	Clustering	Blackbox	Manuell	Software Tool	Visualisation	Format of Usage
VAT01	Technology/ Engineering		X													X		X	X							Gra-phana	Graph (time series)	Dash- board, Report (Email einmal p.W.)
VAT03	Technology/ Engineering		X													X		X	X							Gra-phana	Graph	Graph per Email (einmal p.W.)
VAT04	Technology/ Engineering	X	X											X												Power BI	Graph	Dash- board
VAT05	Technology/ Engineering	X	X													X		X								Power BI	Number/ Text	Dash- board
VAT06	Technology/ Engineering		X													X				X	X	X				Power BI	Number/ Text	Dash- board
VAT12	Technology/ Engineering	X	X													X	X			X	X					Power BI/ Gra-phana	Number/ Text/ Graph	Dash- board
OBE01	Level 3: Engineering/ Systemverantwortlicher / Leiter Mechanik und bei Bedarf technischer GF	X	X	X					X					X				X								Base-View / OBE Analysetool	Base- View / OBE Analyse- tool	Grafik
OBE02	Level 3: Engineering/ Systemverantwortlicher / Leiter Mechanik und bei Bedarf technischer GF	X	X	X					X					X				X								Base-View / OBE Analyse- tool	Base- View / OBE Analyse- tool	Grafik
OBE03	Level 3: Engineering/ Systemverantwortlicher / Leiter Mechanik und bei Bedarf technischer GF	X	X	X					X					X				X								Base-View / OBE Analyse- tool	Base- View / OBE Analyse- tool	Grafik
OBE04	Level 3: Engineering/ Systemverantwortlicher / Leiter Mechanik und bei Bedarf technischer GF	X	X	X					X					X				X								Base-View / OBE Analyse- tool	Base- View / OBE Analyse- tool	Grafik
OBE	Systemverantwortlicher (Specialist)		X						X					X			X			X	X	X	X			TBD	TBD	Grafik
OBE06	Technik-Abteilung / Planungsabteilung (MaWi, Kosten Service-Einsätze, Großkomponenten- tausche)	X	X	X										X											X	Excel	Grafisch (e.g. Balken- diagr.)	Grafik

ID	Comments
DWT02	Informationen über Status: Reset erfolgreich, Netzfehler, Wiederholungsfehler, autom. Selbsttest, System OK
DWT05	L-mobile: Materialhistorie (Excel-Auswertung)
DWT07	Datenabgriff aus L-mobile und Darstellung in Excelliste
DWT09	
DWT18	
DWT32	
DWT33	Statusmeldungen / Fehlerprotokoll Rotorsoft Incidentliste der Anlage (Excel)
DWT35	Die Daten liegen webbasiert und im Tool des jeweiligen Herstellers vor
DWT36	Die Daten liegen webbasiert und im Tool des jeweiligen Herstellers vor
DWT58	Excel, 10-Minuten-Daten aus ROTORsoft oder Steuerung und Auswertungsmöglichkeiten direkt in ROTORsoft als Basis eines Kennliniendiagramms (Windwerte + Leistungswerte) im 10-Minuten-Mittel Separate Auswertungen in Form von Excel oder in Form des Monatsberichts seitens TBF an den Kunden. Werden in der Ordnerstruktur des Windparks abgelegt. Auswertungen der Leistungskurven sind alternativ jederzeit in ROTORsoft abrufbar
DWT64	Status Rotorsoft (In Betrieb / In Störung / Wartung / Stillstand)
DWT65	Fehlermeldung Rotorsoft: manueller Stop, Fehler Steuerung, Fehler Kommunikation, Fehler Umrichter, Fehler Temperatur, Fehler Drehzahl, Sicherheitskette
DWT66	
DWT67	Report Excellisten and E-Mail Mitteilungen

ID	Comments
VAT01	Based on the assumption currently how Vattenfall use it is most likely to report later on the issue no like alarm,. / Impact one turbines or the all wind farm. So Forecast vs actual revenue Machine learning oder Clustering für zukünftige Entwicklung, Data source SCADA
VAT03	For me the cost to development are similar. They are both the same project / pipeline with different source. For the Cost DEC. It look also similar see comment above Filtern als Vorbereitung der Daten, Machine Learning als zukünftige Entwicklung, für die trouble shooter auf der Site, 2nd level support, Data Source SHM
VAT04	
VAT05	Future developement Machine Learning for resolving the dataproduct.
VAT06	The cost is higher because of the need of aligment (Machine learning is used for outlier detection)
VAT12	Fit der Verteilung Indirekt vorbereitend als Zwischenschritt, Graphana für die Erstellung von Grafiken
OBE01	Lagertemperatur, Überspannungsschutzgerät. Daten nur teilweise vollständig, da keine Begutachtung vor Ort (bspw. Zustand Schmiersystem?). KPI ist grundsätzlich immer interessant, lässt sich mit den vorhandenen Mitteln jedoch nicht definitiv beantworten -> Big data. Beispiel Lagertemperatur: Kategorisierung der Auffälligkeit je nach "Schwere" (Dauer, Frequenz), aus der Frequenz der Überwachung resultiert. DEC-Kosten: Kostenschätzung für den Fall, dass Fehler nicht erkannt wird und Instandsetzung notwendig wird (Entstörung oder Großkomponententausch (GKT)). Hier Annahme des Worst-case GKT.
OBE02	Daten: Temperatur, Öldruck. Teilweise Vollständig, da nur remote-Daten und somit fehlende Begutachtung vor Ort. Alarmmeldung bei Auffälligkeiten. KPI ist grundsätzlich immer interessant, lässt sich mit den vorhandenen Mitteln jedoch nicht definitiv beantworten -> Big data. DEC-Kosten: Kostenschätzung für den Fall, dass Fehler nicht erkannt wird und Instandsetzung notwendig wird (Entstörung oder Großkomponententausch (GKT)). Hier Annahme des Worst-case GKT.
OBE03	Datequellen: Partikelzähler, DMS. Teilweise Vollständig, da nur remote-Daten und somit fehlende Begutachtung vor Ort. Alarmmeldung bei Auffälligkeiten. KPI ist grundsätzlich immer interessant, lässt sich mit den vorhandenen Mitteln jedoch nicht definitiv beantworten -> Big data. DEC-Kosten: Kostenschätzung für den Fall, dass Fehler nicht erkannt wird und Instandsetzung notwendig wird (Entstörung oder Großkomponententausch (GKT)). Hier Annahme des Worst-case GKT.
OBE04	Fragestellung nur bei tatsächlich festgestellten Auffälligkeiten relevant, also reaktives Handeln. Keine proaktive Untersuchung der Daten auf Auffälligkeiten. Beispiel Generator: Fehler verhalten sich von WEA zu WEA anders. Es gab einen Fall, bei dem WEA noch 18 Monate nach Auftreten der Fälligkeit lief, in anderen Fällen trat nach wenigen Tagen Störung ein.
OBE05	Multiple Methoden oder Methodenkombinationen möglich.
OBE06	Bsp: Kohlebürsten am Generator bei Jahreswartung. Statistiken werden bei Bedarf für bestimmte Fragestellungen angefertigt (Materialplanung kommende Wartung). Auswertung der Wartungsprotokolle aller 80 WEA. Genauigkeit der Daten abhängig von Fragestellung.


Tab. E.1: Datenprodukttable

VAT Übersicht



F Evaluationsergebnisse Vattenfall

- ROI_{DAQ}: Protokoll, manuelle Datenanalyse (Single point of truth?)
- ROI_{DANA}: Viele Datenanalyse Methoden (Toolbox/ Automatisierungspotential?)
- ROI_{DEC}: Viele hochwertige Entscheidungen (Datengetriebener?), Kostenstruktur




VAT01



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
414%




VAT03



- ROI DAQ**
 - Completeness
 - Accuracy
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
- One time costs Decision value (= Data value)
- Yearly costs Decision value (= Data value)

RoA
826%



VAT04



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
826%




VAT05



- ROI DAQ**
 - Completeness
 - Accuracy
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
- One time costs Decision value (= Data value)
- Yearly costs Decision value (= Data value)

RoA
969%




Data Acquisition Method ID KPI Addresssee

VAT06




- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
- Added value
 - Implementation effort
- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
310%




VAT12




- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
- Added value
 - Implementation effort
- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

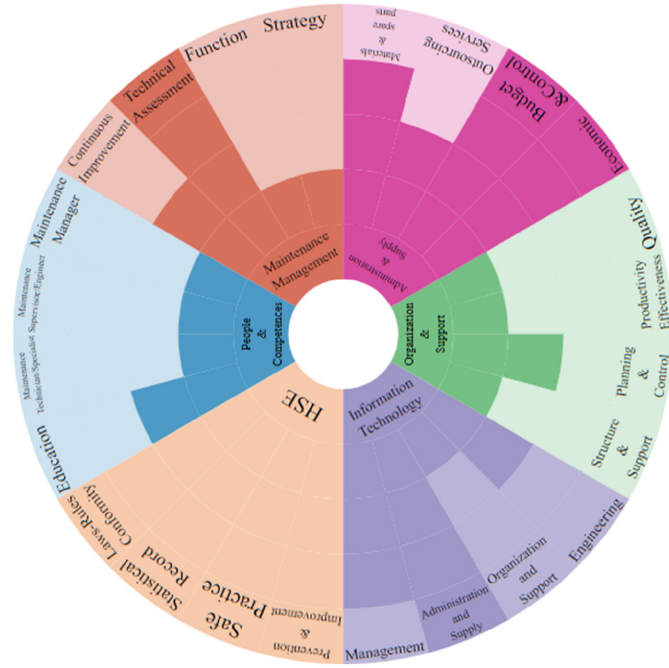
ROA
713%



Im Sankey




Nicht im Sankey



Legende

Category	Subcategory
Maintenance	Sustainability
	Capacity Effectiveness Integrity
	Service Level
Maintenance Engineering	Economics
	Capability & Criticality
	Durability
	Preventive Maintenance
Maintenance Management	Continuous Engineering Improvement
	Strategy
	Function
	Technical Assessment
People & Competences	Continuous Improvement
	Maintenance Manager
	Maintenance Supervisor/Engineer
	Maintenance Technician/Specialist
HSE	Education
	Laws-Rules Conformity
	Statistical Record
	Safe Practice
Information Technology	Prevention & Improvement
	Management
	Administration and Support
	Organization and Support
Organization & Support	Engineering
	Structure & Support
	Planning & Control
	Productivity Effectiveness
Administration & Supply	Quality
	Economic
	Budget & Control
	Outsourcing Services
	Materials & spare parts

OBE Übersicht



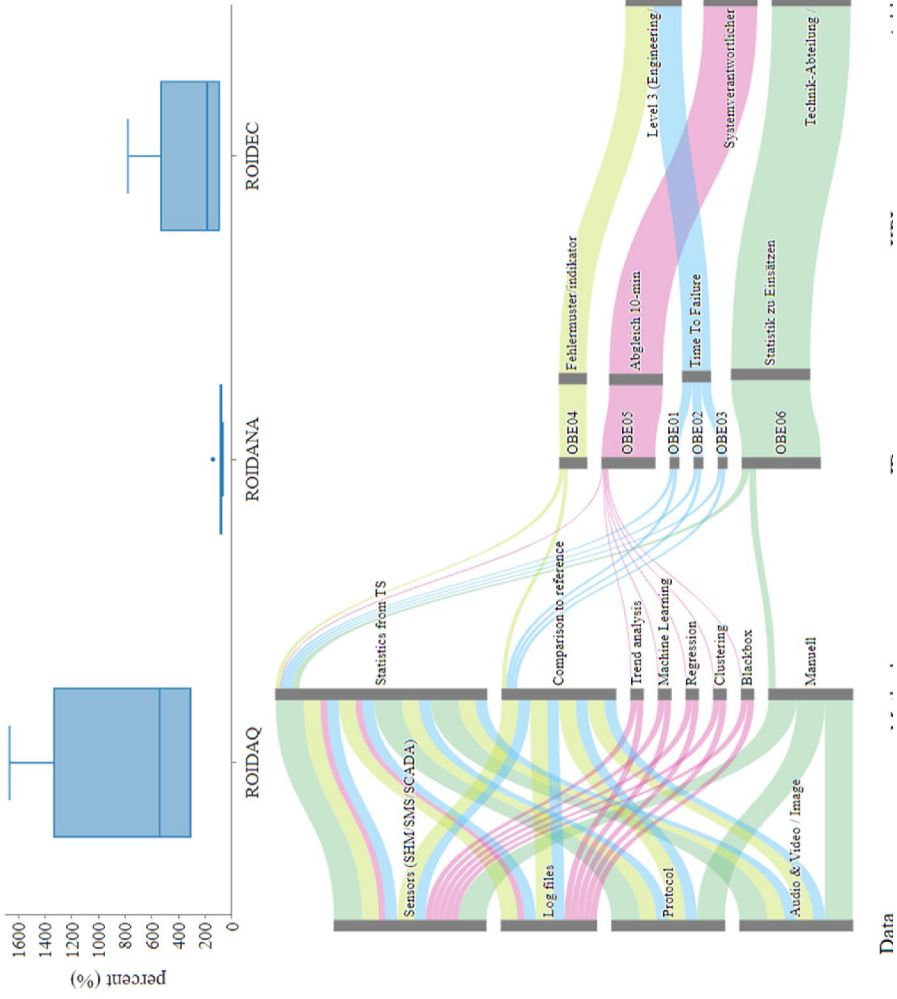
G

Evaluationsergebnisse Ocean Breeze

RoIDAQ: Audio & Video / Bilddaten führen zur manuellen Analyse


RoIDANA: Viele Datenanalyse Methoden und hoher Anteil manueller Auswertungen

RoIDEC: Viele der untersuchten Entscheidungen benötigten multiple Methoden




G

OBE01



- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
- Added value
 - Implementation effort
- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
526%




OBE02




- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
526%




Data Acquisition Method KPI Addressee

OBE03




- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
- Added value
 - Implementation effort
- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
526%



Data Acquisition Method ID KPI Addressee

OBE04




- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

- ROI DANA**
- Added value
 - Implementation effort


- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs

ROA
1740%




Data Acquisition Method ID KPI Addressee

OBE05



- ROI DAQ**
- Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
- Added value
 - Implementation effort
- ROI DEC**
- Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

ROA
1.438%




OBE06



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

ROA
2659%



Data Acquisition

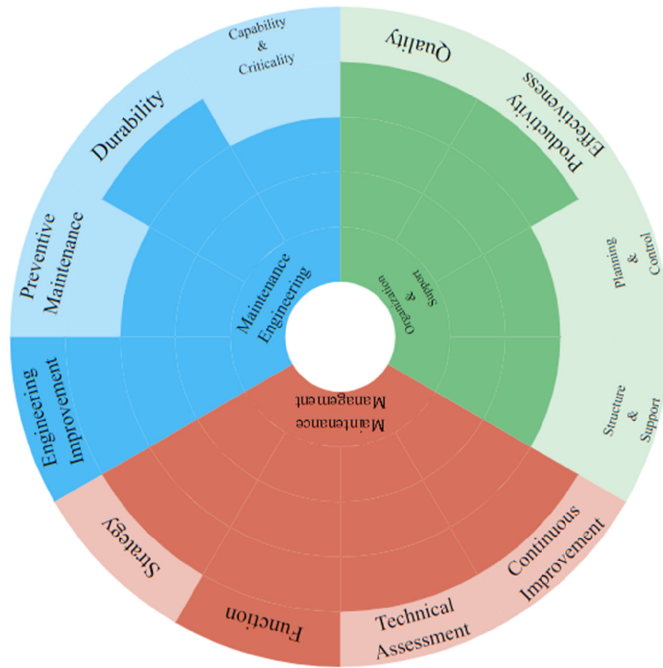
Method

ID

KPI

Adressee

Im Sankey



Nicht im Sankey

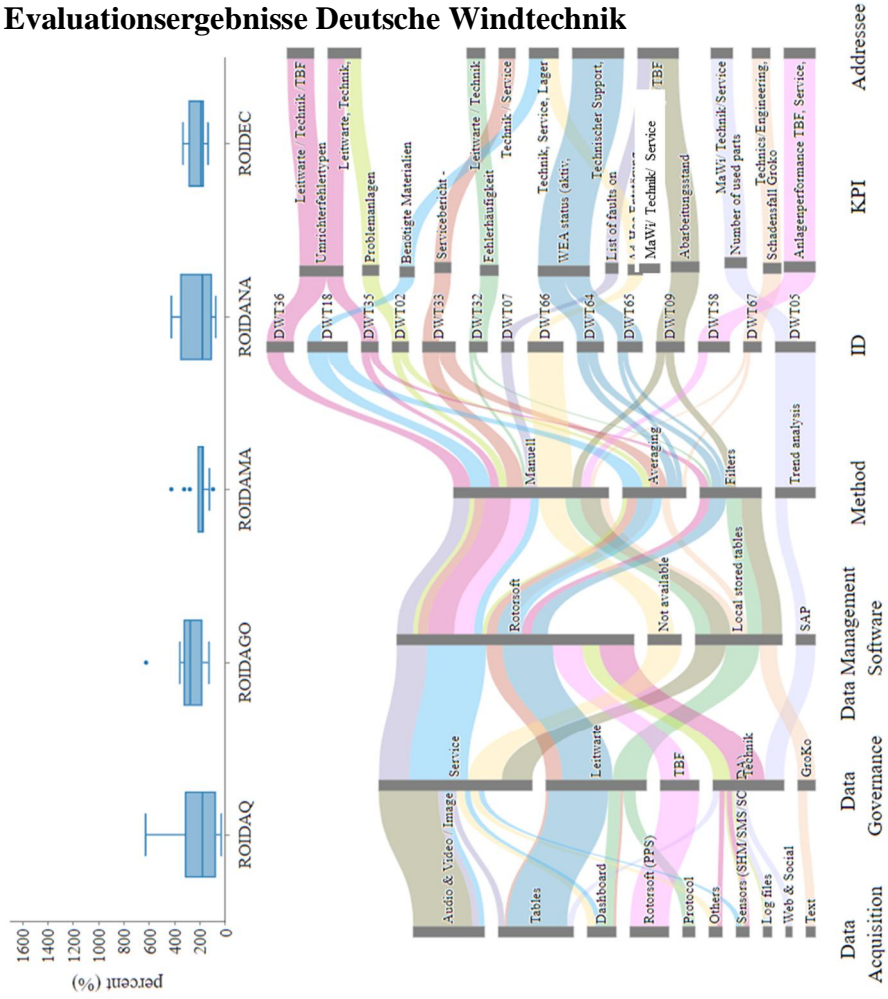


Legende


Category	Subcategory
Maintenance	Sustainability
	Capacity Effectiveness Integrity
	Service Level
Maintenance Engineering	Economics
	Capability & Criticality
	Durability
	Preventive Maintenance
	Continuous Engineering Improvement
Maintenance Management	Strategy
	Function
	Technical Assessment
People & Competences	Continuous Improvement
	Maintenance Manager
	Maintenance Supervisor/Engineer
	Maintenance Technician/Specialist
HSE	Education
	Laws-Rules Conformity
	Statistical Record
	Safe Practice
	Prevention & Improvement
Information Technology	Management
	Administration and Supply
	Organization and Support
Organization & Support	Engineering
	Structure & Support
	Planning & Control
	Productivity Effectiveness
Administration & Supply	Quality
	Economic
	Budget & Control
	Outsourcing Services
	Materials & spare parts

H Evaluationsergebnisse Deutsche Windtechnik


DWT Übersicht




DWT02




- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
728%




DWT05




- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROIDANA**
 - Added value
 - Implementation effort
 - ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- ROA**
1248%



DWT07



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA 935%**



DWT09



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- ROA**
1912%




DWT018




- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
- ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

RoA
1600%

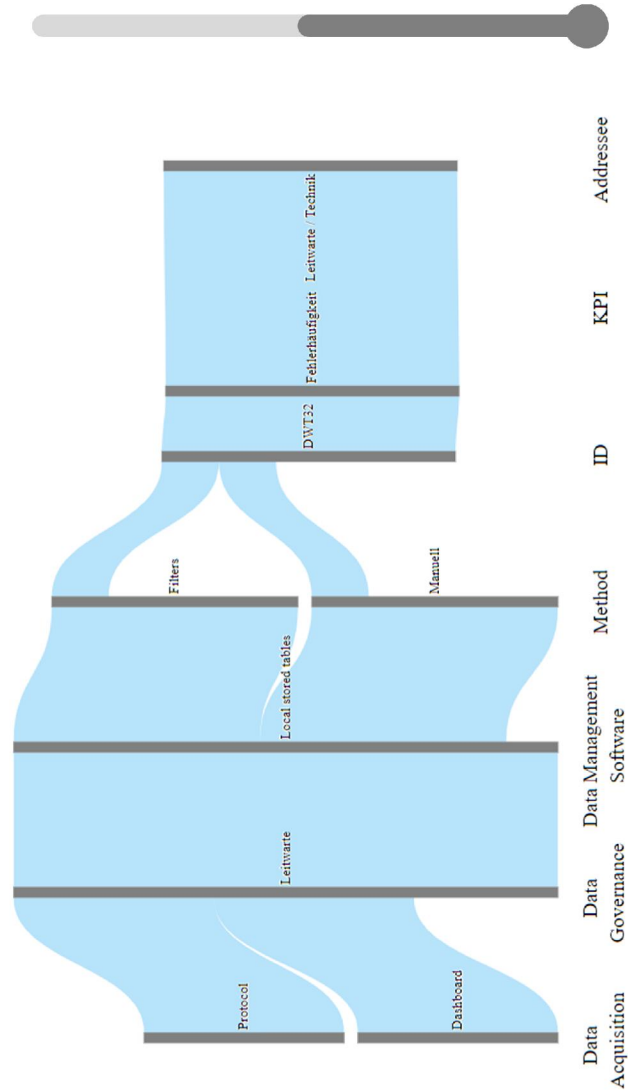


DWT32




- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
- ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
- ROI DANA**
 - Added value
 - Implementation effort
- ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)


ROA
587%




DWT33




- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROIDANA**
 - Added value
 - Implementation effort
 - ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
1019%




DWT35



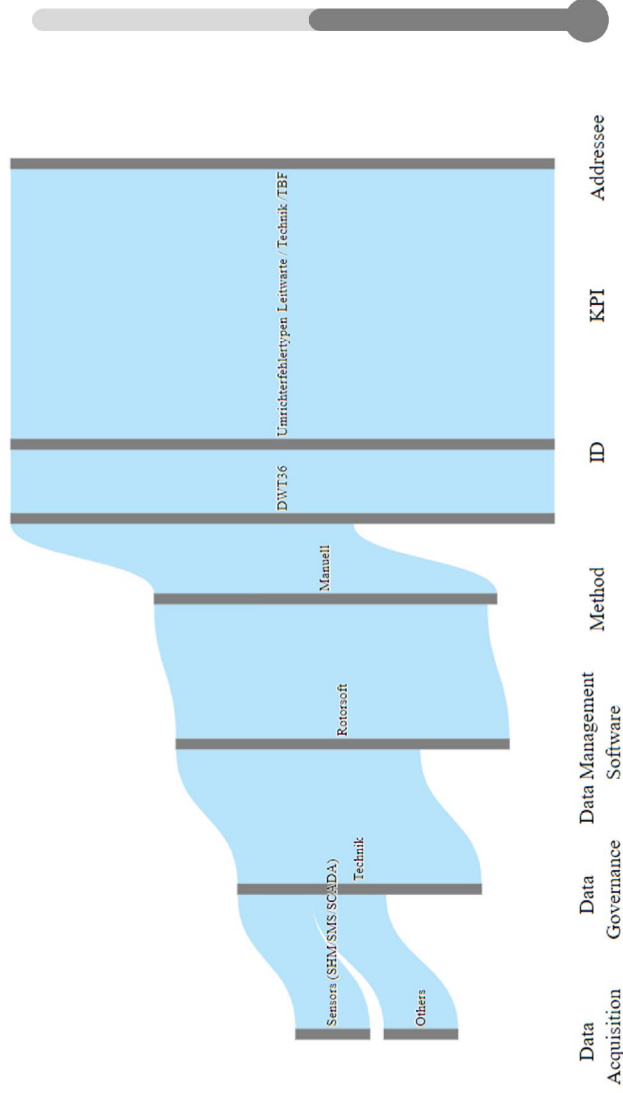
- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
896%



DWT36



- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROIDANA**
 - Added value
 - Implementation effort
 - ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
902%




DWT58

1
2
3
4




- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
- ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
- ROIDANA**
 - Added value
 - Implementation effort
- ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)

ROA
1415%




DWT64



- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
- ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
- ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
- ROIDANA**
 - Added value
 - Implementation effort
- ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)


ROA
1258%




DWT65




- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- ROA**
1228%




DWT66




- ROIDAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROIDAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROIDAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROIDANA**
 - Added value
 - Implementation effort
 - ROIDEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
1398%



DWT67



- ROI DAQ**
 - Completeness
 - Accuracy
 - One time costs
 - Yearly costs
 - ROI DAGO**
 - Integrity
 - Consistency
 - One time cost DAGO
 - Yearly cost DAGO
 - ROI DAMA**
 - Accessibility
 - Credibility
 - Interpretability
 - One time cost DAMA
 - Yearly cost DAMA
 - ROI DANA**
 - Added value
 - Implementation effort
 - ROI DEC**
 - Timeliness
 - Frequency of Usage
 - Relevance
 - One time costs Decision value (= Data value)
 - Yearly costs Decision value (= Data value)
- RoA**
780%





Kundenmanagement Techn.
Betriebsführung (Level 2 + 3)



Außendienst (Level 2)

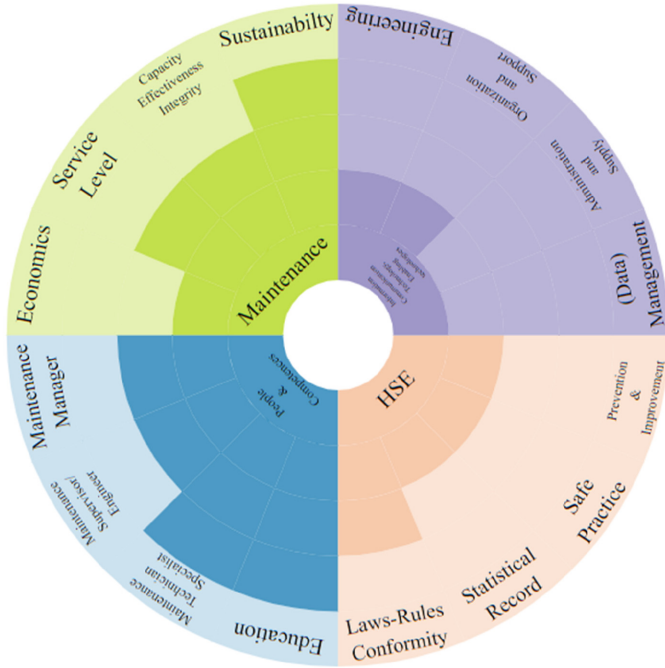


Technik, Leitwarte Mawi
(Level 1 + 3)

Legende

Category	Subcategory
Maintenance	Sustainability
	Capacity Effectiveness Integrity
	Service Level
Maintenance Engineering	Economics
	Capability & Criticality
	Durability
Maintenance Management	Preventive Maintenance
	Continuous Engineering Improvement
	Strategy
People & Competences	Function
	Technical Assessment
	Continuous Improvement
HSE	Maintenance Manager
	Maintenance Supervisor/Engineer
	Maintenance Technician/Specialist
Information Technology	Education
	Laws-Rules Conformity
	Statistical Record
Organization & Support	Safe Practice
	Prevention & Improvement
	Management
Administration & Supply	Administration and Supply
	Organization and Support
	Engineering
Administration & Supply	Structure & Support
	Planning & Control
	Productivity Effectiveness
Administration & Supply	Quality
	Economic
	Budget & Control
Administration & Supply	Outsourcing Services
	Materials & spare parts

Im Sankey Nicht im Sankey



Legende

Category	Subcategory
Maintenance	Sustainability
	Capacity Effectiveness Integrity
	Service Level
Maintenance Engineering	Economics
	Capability & Criticality
	Durability
	Preventive Maintenance
Maintenance Management	Continuous Engineering Improvement
	Strategy
	Function
	Technical Assessment
People & Competences	Continuous Improvement
	Maintenance Manager
	Maintenance Supervisor/Engineer
	Maintenance Technician/Specialist
HSE	Education
	Laws-Rules Conformity
	Statistical Record
	Safe Practice
Information Technology	Prevention & Improvement
	Management
	Administration and Supply
	Organization and Support
Organization & Support	Engineering
	Structure & Control
	Planning & Control
	Productivity Effectiveness
Administration & Supply	Quality
	Economic
	Budget & Control
	Outsourcing Services
	Materials & spare parts

I Freigaben

Global Renewable Shipbrokers:

Doc-No. 674237 14/FEB/2017 (TUE) 11:27 (+0100) PS

GRS GOES GLOBAL >>> NEW GRS-BASE IN SOUTHERN UK; Colchester

Moin Herr Bendlin,

anbei die Bilder. Bei dem SOV mit Transfersystem habe ich leider kein freigestelltes Bild ... nur das Schiff ohne Transfersystem (alles anbei).



Abb. F.1: Offshore-Windpark Logistik Bilder

Die Fotos sollten auch noch etwas in der Helligkeit bearbeitet werden.

Gerne würden wir im Gegenzug Ihre Veröffentlichungen und Doktorarbeit erhalten.

Mit freundlichen Grüßen,

Philippe Schönefeld /// GRS / GLOBAL RENEWABLES SHIPBROKERS GmbH

Stadthausbrücke 7

20355 Hamburg

T +49 40 411 60 68 12 / M +49 172 41 68 447 / F +49 40 411 60 68 99

p.schoenefeld@grs-offshore.com / www.grs-offshore.com

Registered Office: Hamburg / Commercial Registry: HRB 119000 / Managing Director: P. Schönefeld, M. Mroß

GRS performs its services exclusively on the basis of its General Terms and Conditions, which are available at the GRS website www.grs-offshore.com.

Chartering and S&P // Cargo Run // Offshore Equipment // Turnkey Solutions

>>> **GETTING THERE FASTER – WITH GRS** / www.grs-offshore.com

Original Message

From : Bendlin, Dirk (dirk.bendlin@iwes.fraunhofer.de)

To : p.schoenefeld@grs-offshore.com (p.schoenefeld@grs-offshore.com) - dirk.bendlin@uni-oldenburg.de (dirk.bendlin@uni-oldenburg.de) - Matthias Mroß (Global Renewables Shipbrokers) (m.mross@grs-offshore.com)

Subject : Freigabe für Bildmaterial in wissenschaftlichen Veröffentlichungen

Date : 14/02/2017 11:10:08

Moin moin Herr Schönefeld,

vielen Dank für Ihre Freigabe des Bildmaterials. Anbei sende ich Ihnen eine Liste der Benötigten Bilder, die ich für die aktuelle Veröffentlichung freigestellt benötigen würde. Wie ich bereits bei unserem letzten Gespräch erwähnte, promoviere ich aktuell an der Universität Oldenburg zum Thema O&M im Bereich Offshore-Wind. Für diese Promotion arbeite ich an verschiedenen Veröffentlichungen zu Wind und Umweltinformatik Fachtagungen und Konferenzen (z.B. <https://www.sintef.no/projectweb/eera-deepwind2017/> oder <http://buis2017.cs.ovgu.de/>).

Für kommende Konferenzen und meine Doktorarbeit würde ich gerne Bildmaterial (z.B. die verschiedenen Transportmittel) von Ihrer Webseite nutzen und Sie im Gegenzug in diesen Veröffentlichungen lobend erwähnen.

Ich freue mich über Ihre Rückmeldung und die freigestellten Bilddateien. Ich wünsche Ihnen eine erfolgreiche Woche.

P.s. Noch einmal herzlichen Dank für Ihre Unterstützung bei unserem gemeinsamen Forschungsvorhaben COAST 2.0. Mittlerweile haben wir die erste Fragerunde vom PTJ beantwortet und sind damit einen Schritt weiter mit der Projektskizze, so dass wir hoffen in den nächsten Monaten eine Finale Antwort zu bekommen.

Mit freundlichen Grüßen

--

Dirk Bendlin

Wissenschaftlicher Mitarbeiter

Windparkplanung und -betrieb

Fraunhofer-Institut für Windenergie und Energiesystemtechnik IWES

Am Seedeich 45, 27572 Bremerhaven, Germany

Telefon: +49 (0) 471 / 14290 – 368

<http://www.windenergie.iwes.fraunhofer.de>

Ramboll: Excerpt from MS-Teams chat [12.05.2021 12:24] Dirk Bendlin

Hi Ronnie, just a quick question, I need those two pictures below for a publication in a research project. I understood that they can be freely used for such purposes is the © Ramboll as well as a mentioning in the acknowledgements sufficient or do we need anything else? I hope you can help on that one, thank you very much and have a nice day




Abb. F.2: Different types of foundations © Ramboll 2021



Abb. F.3: Offshore Sub Station © Ramboll 2021

[12.05.2021 12:26] Ronnie Refstrup Pedersen

Yes - I believe there are also used in other publications

Die Freigaben der Industriepartner Deutsche Windtechnik, Vattenfall, Iberdrola und Ocean Breeze (im weiteren Industriepartner genannt) erfolgt durch den Kooperationsvertrag des Forschungsprojekts *WiSA Big Data* von allen Industriepartnern am 02.07.2020 unterschrieben.

Das Dissertationsvorhaben wurde den Industriepartnern im Kick-off-Meeting am 14.01.2020 vorgestellt. Entsprechend den in § 7 Vertraulichkeit und Veröffentlichungen genannten Abschnitt 9) wurden alle Industriepartner über den Inhalt der Veröffentlichung am 21.12.2022 über E-Mail informiert (siehe unten).

- 9) Soweit in eine Veröffentlichung Arbeitsergebnisse, Außervertragliche Ergebnisse oder Geheimhaltungsbedürftige Informationen der anderen Partner einfließen, ist der die Veröffentlichung planende Partner verpflichtet, den/die betroffenen anderen Partner mindestens 8 Wochen vor der geplanten Veröffentlichung zu informieren und mindestens 4 Wochen vorher über deren Inhalt zu informieren und kritische Informationen auf Verlangen des betreffenden Partners vor Veröffentlichung zu entfernen. Soweit der betroffene Partner nicht binnen 3 Wochen nach dieser Information Einwände gegen die Veröffentlichung erhebt, gilt seine Zustimmung zur Veröffentlichung als erteilt.

Die Zustimmung darf nicht unbillig verweigert oder verzögert werden.

Abb. F.4: Auszug aus dem Kooperationsvertrag

Firma	Empfängerliste:
Deutsche Windtechnik	Simon Geiselsöder s.geiselsoeder@deutsche-windtechnik.com Benedikt Börgel b.boergel@deutsche-windtechnik.com
Vattenfall	Kira Kaufmann kira.kaufmann@vattenfall.de Adel Haghani adel.haghani@vattenfall.de
Iberdrola	Maria Elena Gonzalez Garcia megonzalez@scottishpower.com
Ocean Breeze	Alexander Lowag Alexander.Lowag@oceanbreeze.de
Ramboll	Dr.-Ing. Tim Fischer Tim.Fischer@ramboll.com Dr.-Ing. Moritz Werther Häckell moritz.haekell@ramboll.com

Der E-Mail-Text wurde nur in Bezug auf die persönliche Anrede angepasst.

-- Please scroll down for English version --

Sehr geehrte *WiSA-Big-Data*-Forschungspartner,

hiermit sende ich Ihnen die für Ihre Firma relevanten Texte für mein Dissertationsvorhaben "**Datengetriebene Entscheidungsprozesse in Großprojekten** - Am Beispiel der Betriebsführung und Instandhaltung von Offshore-Windparks".

Das Dissertationsvorhaben wurde bereits im Kick-Off Meeting am 14.01.2020 vorgestellt. Entsprechend den im §7 Vertraulichkeit und Veröffentlichungen genannten Abschnitt 9) informiere ich euch hiermit über E-Mail über die geplante Veröffentlichung der Resultate als Teil meiner Dissertation.

Bitte kommen sie auf mich zurück, wenn editorische Änderungen vorgenommen werden müssen im Lauf der nächsten 3 Wochen auf mich zurück, damit Ihre Änderungen noch eingearbeitet werden können.

Der Inhalt dieser E-Mail ist als streng vertraulich zu behandeln. Für Rückfragen stehe ich gerne zur Verfügung.

Mit freundlichen Grüßen,

--

Dipl. Ing. (FH) Dirk Bendlin

University of Oldenburg
Department of Computing Science
Business Informatics (Very Large Business Applications)
Ammerländer Heerstr. 114-118; 26129 Oldenburg - GERMANY
Tel. +49 152 53 210 438

E-Mail: dirk.bendlin@uol.de

English:

Dear WiSA Big Data Research Partners,

I hereby send you the texts relevant to your company for my dissertation project "Data-driven decision-making processes in large-scale projects - Using the example of the operation and maintenance of offshore wind farms".

The dissertation project has already been presented in the kick-off meeting on 14.01.2020. According to the §7 Confidentiality and Publications mentioned in section 9) I hereby inform you via email about the planned publication of the results as part of my dissertation.

Please get back to me if editorial changes need to be made over the next 3 weeks so that your changes can still be incorporated.

The content of this email is to be treated as strictly confidential. If you have any questions, please do not hesitate to contact me.

Best regards,

--

Dipl. Ing. (FH) Dirk Bendlin

*University of Oldenburg
Department of Computing Science
Business Informatics (Very Large Business Applications)
Ammerländer Heerstr. 114-118; 26129 Oldenburg - GERMANY*

Tel. +49 152 53 210 438

E-Mail: dirk.bendlin@uol.de

The screenshot shows an email client interface. At the top, there is a search bar and a filter button. Below it, a list of sent emails is displayed, including the subject 'WISA Big Data Dissertationsvorhaben Dirk Bendlin - Revision 0' and the recipient 's.gelselsoeder@deutsche-windtechnik.com'. The main part of the screenshot shows the detailed view of the selected email. The sender is Dirk Bendlin, and the subject is 'WISA Big Data Dissertationsvorhaben Dirk Bendlin - Revision 0'. The email body contains a message in German regarding the dissertation process, mentioning a meeting on 14.01.2020 and a decision on 'Datengetriebene Entscheidungsprozesse in Großprojekten'. A PDF attachment titled '2022-12-21 PhD_REV0...' is visible. The bottom of the screenshot shows a Windows taskbar with various application icons and system tray information.

WISA Big Data Dissertationsvorhaben Dirk Bendlin - Revision 0

Dirk Bendlin
Heute, 19:37
s.gelselsoeder@deutsche-windtechnik.com; b.boergel@deutsche-windtechnik.com; Dirk Bendlin <dirk.bendlin@amboll.com>

Herunterladen
2022-12-21 PhD_REV0...
592 KB

Moin Simon und Benedikt,

ich habe gerade eine Fehlermeldung erhalten von Benedikt anscheinend ist der Dateianhang zu groß gewesen. Ich hoffe sie geht so durch. Anbei der zweite Versuch mit einer kleineren Datei, hiermit sende ich euch die für Deutsche Windtechnik relevanten Texte für mein Dissertationsvorhaben "Datengetriebene Entscheidungsprozesse in Großprojekten - Am Beispiel der Betriebsführung und Instandhaltung von Offshore-Windparks".

Das Dissertationsvorhaben wurde bereits im Kick-Off Meeting am 14.01.2020 vorgestellt. Entsprechend den im §7 Vertraulichkeit und Veröffentlichungen genannten Abschnitt 9) informiere ich euch hiermit über Email über die geplante Veröffentlichung der Resultate als Teil meiner Dissertation.

Bitte kommt im Lauf der nächsten 3 Wochen auf mich zurück wenn editorische Änderungen vorgenommen werden müssen, damit Ihre Änderungen noch eingearbeitet werden können.

Der Inhalt dieser Email ist als streng vertraulich zu behandeln. Für Rückfragen stehe ich gerne zur Verfügung.

Ich wünsche euch frohe Feiertage und einen guten Rutsch ins neue Jahr mit euren Lieben,

Mit freundlichen Grüßen,
Dipl. Ing. (FH) Dirk Bendlin

University of Oldenburg
Department of Computing Science
Business Informatics (Very Large Business Applications)
Ammerländer Heerstr. 114-118; 26129 Oldenburg - GERMANY
Tel. +49 152 53 210 438

E-Mail: dirk.bendlin@uol.de

Abb. F.5: Versandnachweis Freigaben

8 Literaturverzeichnis

- Achmus, M.; Schröder, C. (2014): Installation und Tragverhalten von Bucketgründungen für Offshorebauwerke. *Bautechnik* 91 (9), S. 597–608
- Achmus, M. (2011): Bemessung von Monopiles für die Gründung von Offshore-Windenergieanlagen. *Konzepte und offene Fragen. Bautechnik* 88 (9), S. 602–616
- Ackoff, R. (1989): From Data to Wisdom. *Journal of applied systems analysis* 1 (16), S. 3-9
- Ackoff, R. L. (1999): *Ackoff's best. His classic writings on management.* Wiley, New York/Chichester
- Adams, M. (2019): *QT - question thinking. Die Kunst, die richtigen Fragen zu stellen.* dtv, München
- Agrawal, A.; Gans, J.; Goldfarb, A. (2018): A Simple Tool to Start Making Decisions with the Help of AI. <https://hbr.org/2018/04/a-simple-tool-to-start-making-decisions-with-the-help-of-ai>, 17.08.2022
- Åkerman, M.; Lundgren, C.; Barring, M.; Folkesson, M.; Berggren, V.; Stahre, J.; Engström, U.; Friis, M. (2018): Challenges Building a Data Value Chain to Enable Data-Driven Decisions: A Predictive Maintenance Case in 5G-Enabled Manufacturing. *Procedia Manufacturing* 17, S. 411–418
- Alewine, K.; Chen, W. (2010): *Wind turbine generator failure modes. Analysis and occurrence.* Dallas, Texas. 24.-26.05.2010
- Alinezhad, A.; Khalili, J. (2019): *New Methods and Applications in Multiple Attribute Decision Making (MADM).* International Series in Operations Research and Management Science Ser Bd. 277. Springer International Publishing, Cham
- Almeida, F.; Duarte Santos, J.; Augusto Monteiro, J. (2020): The Challenges and Opportunities in the Digitalization of Companies in a Post-COVID-19 World. *IEEE Engineering Management Review* 48 (3), S. 97–103
- Al-Ruithe, M.; Benkhelifa, E.; Hameed, K. (2019): A systematic literature review of data governance and cloud data governance. *Personal and Ubiquitous Computing* 23 (5-6), S. 839–859
- altexsoft (2017): *How to Structure a Data Science Team: Key Models and Roles to Consider.* <https://www.altexsoft.com/blog/datascience/how-to-structure-data-science-team-key-models-and-roles/>, 06.01.2021

- Anderson, C. (2015): Being data-driven: It's all about the culture.
<https://www.oreilly.com/ideas/being-data-driven-its-all-about-the-culture>, 26.02.2019
- Antão, P.; Calderón, M.; Puig, M.; Michail, A.; Wooldridge, C.; Darbra, R. M. (2016): Identification of Occupational Health, Safety, Security (OHSS) and Environmental Performance Indicators in port areas. *Safety Science* 85, S. 266–275
- Arabnia, H. R.; Daimi, K.; Stahlbock, R.; Soviany, C.; Heilig, L.; Brüßau, K. (2020): Principles of Data Science. *Transactions on computational science and computational intelligence*. Springer International Publishing, Cham
- Aspin, A. (2016): Pro Power BI Desktop. Free Interactive Data Analysis with Microsoft Power BI / Adam Aspin. ITpro collection. Apress, Berkeley, CA
- Azaza, M.; Eskilsson, A.; Wallin, F. (2019): An open-source visualization platform for energy flows mapping and enhanced decision making. *Energy Procedia* 158, S. 3208–3214
- Azevedo, A.; Santos, M. F. (2008): KDD, SEMMA AND CRISP-DM: A parallel overview. IADIS European Conference on Data Mining. Amsterdam. 22.- 27.07.2008
- Baagøe-Engels, V.; Stentoft, J. (2016): Operations and maintenance issues in the offshore wind energy sector. *International Journal of Energy Sector Management* 10 (2), S. 245–265
- Baars, H.; Marschall, T. (2019): Agiles Datenmanagement in Big-Data-Umgebungen: Pi-Architektur. *BI-SPEKTRUM* 2019, S. 36–40
- Bailey, H.; Brookes, K. L.; Thompson, P. M. (2014): Assessing environmental impacts of offshore wind farms: lessons learned and recommendations for the future. *Lessons learned and recommendations for the future. Aquatic Biosystems* 10 (1), S. 8-21
- Balzert, H.; Schröder, M.; Schäfer, C. (2017): *Wissenschaftliches Arbeiten. Ethik, Inhalt & Form wiss. Arbeiten, Handwerkszeug, Quellen, Projektmanagement, Präsentation. Soft skills. 2. Aufl.* Springer Campus, Berlin/Dortmund
- BARC (2016): Global Survey on Data Driven Decision-Making in Businesses. 14 Survey-Based Recommendations on How to Improve Data-Driven Decision-Making. <https://bi-survey.com/data-driven-decision-making-business>, 24.09.2021
- Bendlin, D.; Marx Gómez, J.; Kucwicz, A.; Werther Häckell, M. (2024): The Data Value Chain Ontology. In: Mora, M.; Wang, F.; Marx Gomez, J.; Duran-Limon, H. (Hrsg.): *Development Methodologies for Big Data Analytics Systems*, Cham
- Bendlin, D.; Marx Gómez, J.; Werther Häckell, M. (2023): The Data Value Chain Definition. In: *ICTA-EMoS Conference, (Vollständiges Paper angenommen und im Druck, Veröffentlichung voraussichtlich 2024)*

- Bendlin, D.; Werther Häckel, M.; Schwartzkopf, M.-A.; Kucewicz, A. J.; Marx Gómez, J. (2021): Informationsfluss in der Offshore Windenergie - Ein Referenzprozess für Betriebsführung und Instandhaltung. In: Informatik 2021- Computer Science & Sustainability. 27. September - 01. Oktober 2021 Berlin. GI-edition - Lecture notes in informatics (LNU). Proceedings Volume P-314, Bonn
- Bendlin, D.; Hebig, K.; Wolken-Möhlmann, G.; Marx Gómez, J. (2019): Simulating the Uncertain: Present Status of Operation and Maintenance Simulation for Offshore Wind Farms. In: Marx Gómez, J.; Solsbach, A.; Klenke, T.; Wohlgemuth, V. (Hrsg.): Smart Cities/Smart Regions – Technische, wirtschaftliche und gesellschaftliche Innovationen, Wiesbaden, S. 591–609
- Bendlin, D.; Wolken-Möhlmann, G.; Wiggert, M.; Parker, S.; Marx Gómez, J. (2018): Boundaries of Decision-Making Simulations in Operation and Maintenance of Offshore Wind Farms. 9. BUIS-Tage. Otto-von-Guericke-Universität Magdeburg. 11.- 12.05.2017
- Bendlin, D.; Marx Gómez, J.; Wolken-Möhlmann, G. (2016): Decision support with weather statistics and simulation software for offshore wind farms. EnviroInfo 2016. Hochschule für Technik und Wirtschaft Berlin. 14.- 16.09.2016
- Bernstein, J. H. (2009): The Data-Information-Knowledge-Wisdom Hierarchy and its Antithesis. NASKO 2 (1), S. 68-75
- Berti-Equille, L. (1998): From Data Source Quality to Information Quality: the Relative Dimension. The International Conference on Information Quality (ICIQ). Cambridge. 23.- 25.10.1998
- Bertsimas, D.; Thiele, A. (2006): Robust and Data-Driven Optimization: Modern Decision Making Under Uncertainty. In: Johnson, M. P.; Norman, B.; Secomandi, N. (Hrsg.): Models, Methods, and Applications for Innovative Decision Making, [Place of publication not identified], S. 95–122
- Beyan, O. D.; Handschuh, S.; Koumpis, A.; Frigidis, G.; Decker, S. (2016): A Framework for Applying Data Integration and Curation Pipelines to Support Integration of Migrants and Refugees in Europe. 17th IFIP Advances in Information and Communication Technology. Porto. 03.- 05.10.2016
- Bitkom (2014): Big-Data-Technologien Wissen für Entscheider. <https://kmu-digital.eu/de/service-kompetenz/publikationen/broschueren/4-big-data-technologien-wissen-fuer-entscheider>, 05.07.2023
- Bjerregaard Orby, R. (2020): Sustainability Toolbox. <https://ramboll.com/ingenuity/sustainability-toolbox>, 25.10.2021

- Blinder, R.; Biller, O.; Even, A.; Sofer, O.; Tractinsky, N.; Lanir, J.; Bak, P. (2019): Comparative Evaluation of Node-Link and Sankey Diagrams for the Cyber Security Domain. Human-Computer Interaction – INTERACT. Paphos. 02.- 06.09.2019
- Blume, S. A. (2020): Resource Efficiency in Manufacturing Value Chains. Sustainable production, life cycle engineering and management. Springer International Publishing, Cham
- Bosnjak, Z.; Grljevic, O.; Bosnjak, S. (2009): CRISP-DM as a framework for discovering knowledge in small and medium sized enterprises' data. 5th International Symposium on Applied Computational Intelligence and Informatics (SACI). Timisoara. 28.- 29.05.2009
- Brath, R.; Jonker, D. (2015): Graph analysis and visualization. Discovering business opportunity in linked data. John Wiley & Sons, Indianapolis, IN
- Breitfuss, G.; Fruhwirth, M.; Wolf-Brenner, C.; Riedl, A.; de Reuver, M.; Ginthoer, R.; Pimas, O. (2020): Data Service Cards - A supporting tool for Data-Driven Business. 33rd Bled eConference Enabling Technology for a Sustainable Society. online conference. 28.- 29.06.2020
- Breitfuss, G.; Fruhwirth, M.; Pammer-Schindler, V.; Stern, H.; Dennerlein, S. (2019): The Data-Driven Business Value Matrix - A Classification Scheme for Data-Driven Business Models. 32nd Bled eConference digital transformation: humanizing technology for a sustainable society. Bled. 16.- 09.06.2019
- Brühl, V. (2019): Big Data, Data Mining, Machine Learning und Predictive Analytics – ein konzeptioneller Überblick. CFS Working Paper Series, No. 617 2019, S. 1-13
- BSH (2015): Standard Konstruktion - Mindestanforderungen an die konstruktive Ausführung von Offshore-Bauwerken in der ausschließlichen Wirtschaftszone (AWZ). 1. Aufl. Bundesamt für Seeschifffahrt und Hydrographie (BSH), <https://www.bsh.de/>, 16.02.2022
- Buchanan, L.; O'Connell, A. (2006): A brief history of decision making. <http://samuellearning.org/decisionmaking/handout1.pdf>, 30.01.2024
- Carroll, J.; McDonald, A.; McMillan, D. (2016): Failure rate, repair time and unscheduled O&M cost analysis of offshore wind turbines. Wind Energy 19 (6), S. 1107–1119
- Carroll, J.; May, A.; McDonald, A.; McMillan, D. (2015): Availability Improvements from Condition Monitoring Systems and Performance Based Maintenance Contracts. The European Wind Energy Association (EWEA) Offshore. Copenhagen. 10.- 12.03.2015
- Cavanillas, J. M., Curry, E., Wahlster, W. (Hrsg.) (2016): New Horizons for a Data-Driven Economy. A Roadmap for Usage and Exploitation of Big Data in Europe. 1. Aufl. Springer International Publishing, Cham

- CEN (August 2019): Maintenance Key Performance Indicators. EN 15341:2019. Danish Standards Foundation, European Committee for Standardization
- CEN (März 2007): Maintenance — Maintenance Key Performance Indicators. EN 15341:2007(E). BSI British Standards, European Committee for Standardization
- Chagnes, A.; Cote, G.; Ekberg, C.; Nilsson, M.; Retegan, T. (2016): WEEE recycling. Research, development, and policies / edited by Alexandre Chagnes, Gérard Cote, Christian Ekberg, Mikael Nilsson, Teodora Retegan. 1. Aufl. Elsevier, Amsterdam
- Chapman, P.; Clinton, J.; Kerber, R.; Khabaza, T. (2000): CRISP-DM 1.0 - Step-by-step data mining guide. <http://www.crisp-dm.org/CRISPWP-0800.pdf>, 11.06.2023
- Chen Nielsen, N.; Tillisch, N. (2021): Return on Ambition. A Radical Approach to Your Achievement, Growth, and Well-Being. Fast Company Press, New York
- Chen, H.; Chiang, R. H. L.; Storey, V. C. (2012): Business Intelligence and Analytics: From Big Data to Big Impact. MIS quarterly 36 (4), S. 1165-1188
- Chen, J.; Kim, M.-H. (2022): Review of Recent Offshore Wind Turbine Research and Optimization Methodologies in Their Design. Journal of Marine Science and Engineering 10 (1), S. 28-48
- Cielen, D.; Meysman, A.; Ali, M. (2016): Introducing data science. Big data, machine learning, and more, using Python tools. Manning Publications, Shelter Island NY
- Cohn, M. (2004): User stories applied. For agile software development. The Addison-Wesley signature series. Addison-Wesley, Boston./London
- Dai, L.; Stålhane, M.; Utne, I. B. (2015): Routing and Scheduling of Maintenance Fleet for Offshore Wind Farms. Wind Engineering 39 (1), S. 15–30
- DasScrumTeam AG (2020): Was ist eine User Story? <https://www.dasscrumteam.com/de/user-stories>, 12.07.2021
- Davenport, T.; Patil, D. J. (2012): Data Scientist: The Sexiest Job of the 21st Century. Meet the people who can coax treasure out of messy, unstructured data. <https://hbr.org/2012/10/data-scientist-the-sexiest-job-of-the-21st-century>, 08.07.2023
- Deutsche Windtechnik AG (2020): Deutsche Windtechnik erreicht neuen Meilenstein: Windenergieanlagen mit mehr als 10 GW Nennleistung im Service – größter ISP in Europa und vermutlich auch weltweit. https://www.wab.net/fileadmin/media/News/Pressemitteilungen/2020/Nov_2020/Pi_Deutsche_Windtechnik_10GW_Meilenstein.pdf, 03.06.2023
- Dhungana, S. (2019): On Building Effective Data Science Teams. <https://medium.com/craftdata-labs/on-building-effective-data-science-teams-4813a4b82939>, 08.01.2021

- Dietrich, D., Heller, B., Yang, B. (Hrsg.) (2015): Data science & big data analytics. John Wiley & Sons, Hoboken
- DIN (2019): DIN 31051:2019-06 Fundamentals of maintenance. 2019. Aufl., Deutsches Institut für Normung e. V (DIN)
- Dinter, B.; Kollwitz, C. (2016): Towards a Framework for Open Data Related Innovation Contests. Pre-ICIS Special Interest Group On Decision Support and Analytics (SIGDSA). Dublin. 11.12.2023
- Dinwoodie, I.; McMillan, D.; Revie, M.; Lazakis, I.; Dalgic, Y. (2013): Development of a Combined Operational and Strategic Decision Support Model for Offshore Wind. Energy Procedia 35, S. 157–166
- Dobрева, S. (2018): Defining Data Science: The What, Where and How of Data Science. <https://365datascience.com/defining-data-science/>, 29.12.2020
- Dorard, L. (2019): The Machine Learning Canvas —template + handbook. A framework for innovators and visionary managers striving to design tomorrow’s Machine Learning systems. <https://medium.com/louis-dorard/new-book-the-machine-learning-canvas-45bb860307f5>, 25.11.2022
- Dyer, J.; Gregersen, H. B.; Christensen, C. M. (2011): The innovator's DNA. Mastering the five skills of disruptive innovators. Harvard Business Press, Boston
- Ederer, N. (2016): The price of rapid offshore wind expansion in the UK: Implications of a profitability assessment. Implications of a profitability assessment. Renewable Energy 92, S. 357–365
- Emmanouilidis, C.; Bertoucelj, L.; Bevilacqua, M.; Tedeschi, S.; Ruiz-Carcel, C. (2018): Internet of Things - Enabled Visual Analytics for Linked Maintenance and Product Lifecycle Management. IFAC-PapersOnLine 51 (11), S. 435–440
- Endrerud, O.-E. V.; Liyanage, J. P.; Keseric, N. (2014): Marine logistics decision support for operation and maintenance of offshore wind parks with a multi method simulation model. Winter Simulation Conference (WSC). Savannah, GA. 07.- 10.12.2014
- EWE ENERGIE AG (2015): Innerparkverkabelung. <http://www.riffgat.de/technik/innerparkverkabelung/>, 14.10.2015
- Fahrmeir, L.; Heumann, C.; Künstler, R.; Pigeot, I.; Tutz, G. (2016): Statistik. Der Weg zur Datenanalyse. Springer-Lehrbuch. 8. Aufl. Springer, Berlin, Heidelberg
- Faroukhi, A. Z.; El Alaoui, I.; Gahi, Y.; Amine, A. (2020): Big data monetization throughout Big Data Value Chain: a comprehensive review. Journal of Big Data 7 (1), S. 1–22

- Faulstich, S.; Hahn, B.; Tavner, P. J. (2011): Wind turbine downtime and its importance for offshore deployment. *Wind Energy* 14 (3), S. 327–337
- fino-offshore.de (2019): FINO - Forschungsplattformen in Nord- und Ostsee. <http://www.fino-offshore.de/de/>, 16.02.2022
- Fleming, O.; Fountaine, T.; Henke, N.; Saleh, T. (2018): Ten red flags signaling your analytics program will fail. <https://www.mckinsey.com/capabilities/quantumblack/our-insights/ten-red-flags-signaling-your-analytics-program-will-fail>, 30.01.2024
- Foroughi, F.; Luksch, P. (2018): Data Science Methodology for Cybersecurity Projects. *Computers and Society (cs.CY); Cryptography and Security (cs.CR)* 12.05.2018, S. 1–14
- FOWIND (2014): Offshore Wind Policy and Market Assessment. A Global Outlook. <https://gwec.net/fowind-launches-global-offshore-wind-policy-assessment-outlook/>, 30.01.2024
- Freeman, K.; Hundleby, G.; Nordstrom, C.; Roberts, A.; Valpy, B.; Wilow, C.; Totaro, P.; Ayuso, M.; Boshell, F. (2016): Innovation Outlook. Offshore Wind // Offshore wind. International Renewable Energy Agency (IRENA); International Renewable Energy Agency, Abu Dhabi
- Fruhvirth, M.; Breitfuss, G.; Pammer-Schindler, V. (2020): The Data Product Canvas: A Visual Collaborative Tool for Designing Data-Driven Business Models. 33rd Bled eConference Enabling Technology for a Sustainable Society. online conference. 28.- 29.06.2020
- Fryman, L.; Lampshire, G.; Meers, D. (2016): Purpose, Scope and Audience. In: Fryman, L.; Lampshire, G.; Meers, D. (Hrsg.): *The data and analytics playbook. Proven methods for governed data and analytic quality*, Amsterdam, S. 1–21
- Gajewski, T. (2004): Referenzmodell zur Beschreibung der Geschäftsprozesse von After-Sales-Dienstleistungen unter besonderer Berücksichtigung des Mobile Business. HNI-Verlagsschriftenreihe Bd. 158. HNI, Paderborn
- Gao, Y.; Janssen, M. (2022): The Open Data Canvas—Analyzing Value Creation from Open Data. *Digital Government: Research and Practice* 3 (1), S. 1–15
- Geldermann, J.; Lerche, N. (2014): Leitfaden zur Anwendung von Methoden der multikriteriellen Entscheidungsunterstützung. Methode: PROMETHEE. <https://www.uni-goettingen.de/de/document/download/285813337d59201d34806cfc48dae518-en.pdf/MCDA-Leitfaden-PROMETHEE.pdf>, 17.09.2021
- Gelman, A.; Basbøll, T. (2014): When Do Stories Work? Evidence and Illustration in the Social Sciences. *Evidence and Illustration in the Social Sciences. Sociological Methods & Research* 43 (4), S. 547–570

- Glaser, B. G.; Strauss, A. L. (2017): The Discovery of Grounded Theory. Strategies for qualitative research. Routledge, London/New York
- Gonzalez, E.; Nanos, E. M.; Seyr, H.; Valldecabres, L.; Yürüşen, N. Y.; Smolka, U.; Muskulus, M.; Melero, J. J. (2017): Key Performance Indicators for Wind Farm Operation and Maintenance. *Energy Procedia* 137, S. 559–570
- Gonzalez-Rodriguez, A. G. (2017): Review of offshore wind farm cost components. *Energy for Sustainable Development* 37, S. 10–19
- Gottschall, J.; Gribben, B.; Stein, D.; Würth, I. (2017): Floating lidar as an advanced offshore wind speed measurement technique: current technology status and gap analysis in regard to full maturity. *Wiley Interdisciplinary Reviews: Energy and Environment* 6 (5), S. 250-266
- Gregersen, H. (2018): Better brainstorming: focus on questions, not answers, for breakthrough insights. *Harvard Business Review* 96 (2), S. 64-71
- Greiner, S.; Appel, S.; Joschko, P.; Renz, T.; Albers, H. (2015): GOWOG. German Offshore Wind Operation Guide. Leitfaden für die technische Betriebsführung. http://www.systop-wind.de/fileadmin/pdf/systop_gowog_20150630_webseite.pdf, 15.03.2017
- Gronau, N.; Thim, C.; Fohrholz, C. (2016): Business Analytics in der deutschen Praxis. *Controlling* 28 (8-9), S. 472–479
- Gross, D.; Thomsen, C.; OPITZ CONSULTING (2016): Advanced Analytics - Die konsequente Antwort auf Big Data. *Predictive & Advanced Analytics 2016*, S. 1-5
- Gudehus, T. (2010): Logistik. Grundlagen, Strategien, Anwendungen. 4. Aufl. Springer, Berlin, Heidelberg
- Haneke, U. (Hrsg.) (2019): Data Science. Grundlagen, Architekturen und Anwendungen. 1. Aufl. Edition TDWI. dpunkt.verlag, Heidelberg
- Hansch, H. (2011): Nutzen-Kosten-Analyse. Vahlens Kurzlehrbücher. 3. Aufl. Vahlen, München
- Hau, E. (2013): Wind Turbines. Fundamentals, technologies, application, economics. 3. Aufl. Springer, Berlin, Heidelberg
- Hay, L.; Duffy, A. H. B.; McTeague, C.; Pidgeon, L. M.; Vuletic, T.; Grealy, M. (2017): A systematic review of protocol studies on conceptual design cognition: Design as search and exploration. *Design Science* 3, S. 1-36
- Heesen, M. (2009): Innovationsportfoliomanagement. Bewertung von Innovationsprojekten in kleinen und mittelgroßen Unternehmen der Automobilzulieferindustrie. Gabler Verlag, Wiesbaden

- Heidmann, R. (2015): Windenergie und Logistik. Losgröße 1: Logistikmanagement im Maschinen- und Anlagenbau mit geringen Losgrößen. Praxis Management. 1. Aufl. Beuth, Berlin/Wien/Zürich
- Heinrichs, V. (2019): Was ist denn Data Science?
<https://www.wirtschaftsforum.de/expertenwissen/was-ist-denn-data-science>, 29.12.2020
- Hernandez, A. G.; Lupton, R.; Williams, C.; Cullen, J. (2017): From control data to real-time resource maps in a steel-making plant. *Energy Procedia* 142, S. 2377–2383
- Hevner Alan, R. (2007): A Three Cycle View of Design Science Research. *Scandinavian Journal of Information Systems* 19 (2), S. 87–92
- Hevner, A.; Chatterjee, S. (2010): *Design Research in Information Systems*. Bd. 22. Springer US, Boston, MA
- Hevner, A. R.; March, S. T.; Park, J.; Ram, S. (2004): Design Science in Information Systems Research. *MIS quarterly* 28 (1), S. 75-105
- Hey, A. J. G.; Tansley, S.; Tolle, K. M. (2009): *The fourth paradigm. Data-intensive scientific discovery* / edited by Tony Hey, Stewart Tansley, and Kristin Tolle. Microsoft Research, Redmond, Wash.
- Higgins, P.; Foley, A. (2014): The evolution of offshore wind power in the United Kingdom. *Renewable and Sustainable Energy Reviews* 37, S. 599–612
- Hobohm, J.; Krampe, L.; Peter, F.; Gerken, A.; Heinrich, P.; Richter, M. (2013):
Kostensenkungspotenziale der Offshore-Windenergie in Deutschland. Langfassung.
https://www.offshore-stiftung.de/sites/offshorelink.de/files/pictures/SOW_Download-Langfassung_Studie_Kostensenkungspotenziale_Offshore-Windenergie.pdf, 05.02.2024
- Hötzl, F. W. (2022): Erstellung und Evaluation eines Data Product Steckbriefs. Masterthesis, Carl von Ossietzky Universität Oldenburg
- Howells, J. (2020): Building High Performing Data Science Teams.
<https://towardsdatascience.com/building-high-performing-data-science-teams-6e9f160c5c94>, 11.06.2023
- Humby, C. (2006): Data is the New Oil.
https://ana.blogs.com/maestros/2006/11/data_is_the_new.html, 28.02.2022
- Hunke, F.; Seebacher, S.; Thomsen, H. (2020): Please Tell Me What to Do – Towards a Guided Orchestration of Key Activities in Data-Rich Service Systems. 15th International Conference on Design Science Research in Information Systems and Technology, DESRIST. Kristiansand. 02.- 04.12.2020

- IAM (2012): Asset Management – an anatomy. www.theIAM.org/AMA, 30.01.2024
- IBM (2016): IBM SPSS Modeler CRISP-DM Guide.
https://www.ibm.com/docs/it/SS3RA7_18.3.0/pdf/ModelerCRISPDm.pdf, 04.06.2023
- Ibrahim, R.; Yen Yen, S. (2011): A Formal Model for Data Flow Diagram Rules. *ARNP Journal of Systems and Software* 1 (2) May 2011, S. 60-69
- Igual, L.; Seguí, S. (2017): Introduction to Data Science. A Python Approach to Concepts, Techniques and Applications. Undergraduate Topics in Computer Science. Springer International Publishing, Cham
- Ioannou, A.; Angus, A.; Brennan, F. (2018): Parametric CAPEX, OPEX, and LCOE expressions for offshore wind farms based on global deployment parameters. *Energy Sources, Part B: Economics, Planning, and Policy* 13 (5), S. 281–290
- Irawan, C. A.; Ouelhadj, D.; Jones, D.; Stålhane, M.; Sperstad, I. B. (2017): Optimisation of maintenance routing and scheduling for offshore wind farms. *European Journal of Operational Research* 256 (1), S. 76–89
- Jifa, G.; Lingling, Z. (2014): Data, DIKW, Big Data and Data Science. *Procedia Computer Science* 31, S. 814–821
- Jilani, A. A. A.; Nadeem, A.; Kim, T.-H.; Cho, E.-S. (2008): Formal Representations of the Data Flow Diagram: A Survey. *International Conference on Advanced Software Engineering & Its Applications*. Hainan Island. 13.- 15.12.2008
- Kaiser, C.; Stocker, A.; Viscusi, G.; Fellmann, M.; Richter, A. (2021): Conceptualising value creation in data-driven services: The case of vehicle data. *International Journal of Information Management* 59, S. 1-15
- Kaiser, R. (2021): *Qualitative Experteninterviews. Konzeptionelle Grundlagen und praktische Durchführung*. Elemente der Politik. 2. Aufl. Springer, Wiesbaden
- Kampakis, S. (2020): *The Decision Maker's Handbook to Data Science. A Guide for Non-Technical Executives, Managers, and Founders*. 2. Aufl. Apress, Berkeley, CA
- Kaufmann, M. (2019): Big Data Management Canvas: A Reference Model for Value Creation from Data. *Big Data Cogn. Comput. (Big Data and Cognitive Computing)* 3 (1), S. 19-37
- Kayser, L.; Mueller, R.; Kronsbein, T. (2019): Data Collection Map: A Canvas for Shared Data Awareness in Data-Driven Innovation Projects. *Pre-ICIS SIGDSA Symposium*. München. 14.- 15.12.2019
- Keimer, I.; Egle, U. (2020): *Die Digitalisierung der Controlling-Funktion. Anwendungsbeispiele aus Theorie und Praxis*. Springer, Wiesbaden

- Kenett, R.; Redman, T. C. (2019): The real work of data science. Turning data into information, better decisions, and stronger organizations. Wiley, Hoboken, NJ, USA
- Kerzel, U. (2021): Enterprise AI Canvas Integrating Artificial Intelligence into Business. *Applied Artificial Intelligence* 35 (1), S. 1–12
- Kesari, G. (2020): The 5 Roles That Every Data Science Team Must Hire.
<https://www.forbes.com/sites/ganeskesari/2020/11/24/the-5-roles-that-every-data-science-team-must-hire/>, 12.01.2021
- Kim, M.; Zimmermann, T.; DeLine, R.; Begel, A. (2016): The emerging role of data scientists on software development teams. ICSE '16: 38th International Conference on Software Engineering. Austin Texas. 14.- 22.05.2016
- Kirchhoff, S.; Kuhnt, S.; Lipp, P.; Schlawin, S. (2010): Der Fragebogen. Datenbasis, Konstruktion und Auswertung. Lehrbuch. 5. Aufl. VS Verlag für Sozialwissenschaften, Wiesbaden
- Klein, A. (2009): Datenqualität in Sensordatenströmen. Dissertation, Technische Universität Dresden
- Kolkman, D. A.; Sneep, R. (2019): Challenges to Data Science Projects with SMEs: An Analysis and Decision Support Tool. *SSRN Electronic Journal* 2019, S. 1-5
- Koltsidopoulos Papatzimos, A. (2019): Data-driven Operations & Maintenance for Offshore Wind Farms: Tools and Methodologies. Dissertation, Universität Exeter
- Konstantinidis, E. I.; Botsaris, P. N. (2016): Wind turbines: current status, obstacles, trends and technologies. *IOP Conference Series: Materials Science and Engineering* 161, S. 1-8
- Kordon, A. K. (2020): Applying Data Science. How to create value with artificial intelligence. Springer International Publishing; Springer, Cham
- Kostka, G., Fiedler, J. (Hrsg.) (2016): Large Infrastructure Projects in Germany. Springer International Publishing, Cham
- Koutsopoulos, G.; Bider, I. (2018): Business Process Canvas as a Process Model in a Nutshell. In: Gulden, J.; Reinhartz-Berger, I.; Schmidt, R.; Guerreiro, S.; Guédria, W.; Bera, P. (Hrsg.): Enterprise, Business-Process and Information Systems Modeling. 19th International Conference, BPMDS 2018, 23rd International Conference, EMMSAD 2018, Held at CAiSE 2018, Tallinn, Estonia, June 11-12, 2018, Proceedings. *Lecture Notes in Business Information Processing* Ser Bd. 318, Cham, S. 49–63
- Kronsbein, T.; Mueller, R. (2019): Data Thinking: A Canvas for Data-Driven Ideation Workshops. 52nd Hawaii International Conference on System Sciences (HICSS-52). Grand Wailea, Hawaii. 08.- 11.01.2019

- Kruse, F.; Dmitriyev, V.; Marx Gómez, J. (2018): Building a Connection Between Decision Maker and Data-Driven Decision Process. *Archives of Data Science, Series A* 4 (1), S. 1–16
- Kruse, F. (2017): Konzept für die Nutzung von Data Science zur Unterstützung des datengetriebenen Entscheidungsprozesses. Masterarbeit, Carl von Ossietzky Universität Oldenburg
- Kuckartz, U. (2014): *Mixed Methods. Methodologie, Forschungsdesigns und Analyseverfahren.* Lehrbuch. Springer, Wiesbaden
- Kühn, A.; Joppen, R.; Reinhart, F.; Röltgen, D.; Enzberg, S. von; Dumitrescu, R. (2018): Analytics Canvas – A Framework for the Design and Specification of Data Analytics Projects. *Procedia CIRP* 70, S. 162–167
- Kühnapfel, J. B. (2019): *Nutzwertanalysen in Marketing und Vertrieb.* Springer, Wiesbaden
- Kühne, B.; Böhmman, T. (2019): *Data-Driven Business Models - Building the Bridge Between Data and Value.* European Conference on Information Systems (ECIS). Stockholm & Uppsala. 08.- 14.06.2019
- Kühne, V. (2014): Die Revolution von Vindeby. <https://energiewinde.orsted.de/trends-technik/vindeby-erster-offshore-windpark-daenemark>, 10.01.2017
- Lacal-Arántegui, R.; Yusta, J. M.; Domínguez-Navarro, J. A. (2018): Offshore wind installation: Analysing the evidence behind improvements in installation time. *Renewable and Sustainable Energy Reviews* 92, S. 133–145
- Lachal, B. (2019): *Energy Transition.* ISTE Ltd/John Wiley and Sons Inc, Hoboken
- Lacruz, A. J.; Oliveira Leite, M. C. (2021): *Research Project Canvas.* v1.1. https://www.researchgate.net/publication/349771536_Research_Project_Canvas, 21.08.2022
- Lammers, C.-H. (2006): Bedeutung emotionsfokussierter Konzepte und Interventionen für die kognitive Verhaltenstherapie. *Der Nervenarzt* 77 (9), S. 1040-1050
- Laney, D. B. (2018): *Infonomics. How to monetize, manage, and measure information as an asset for competitive advantage.* Bibliomotion, Oxon
- Law, H.; Koutsos, V. (2020): Leading edge erosion of wind turbines: Effect of solid airborne particles and rain on operational wind farms. *Wind Energy* 23 (10), S. 1955–1965
- Lewin, K. (1946): Action Research and Minority Problems. *Journal of social issues* 2 (4), S. 34–46
- Li, W.; Thiede, S.; Kara, S.; Herrmann, C. (2017): A Generic Sankey Tool for Evaluating Energy Value Stream in Manufacturing Systems. *Procedia CIRP* 61, S. 475–480
- Longford, N. T. (2013): *Statistical Decision Theory.* Springer, Berlin/Heidelberg

- Loukides, M. (2011): The evolution of data products. The data that drives products is shifting from overt to covert. <https://www.oreilly.com/ideas/evolution-of-data-products>, 15.08.2020
- Lynn, P. A. (2012): Onshore and offshore wind energy. An introduction. Wiley, Chichester
- Mahanti, R. (2021): Data Governance Success. Growing and Sustaining Data Governance. Springer eBook Collection. 1. Aufl. Springer, Singapore
- Manyika, J.; Chui, M.; Brown, B.; Bughin, J. (2011): Big Data: The next frontier for innovation, competition and productivity. <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/big-data-the-next-frontier-for-innovation>, 15.08.2020
- Mariscal, G.; Marbán, Ó.; Fernández, C. (2010): A survey of data mining and knowledge discovery process models and methodologies. *The Knowledge Engineering Review* 25 (2), S. 137–166
- Marx Gómez, J. C.; Junker, H.; Odebrecht, S. (2009): IT-Controlling. Strategien, Werkzeuge, Praxis. E. Schmidt, Berlin
- Mathis, K.; Köbler, F. (2018): Data Canvas und Data-Need Fit – Daten für neue Geschäftsmodelle nutzen. In: *Management digitaler Plattformen*, Springer, Wiesbaden, S. 313–322
- Mayring, P.; Fenzl, T. (2019): Qualitative Inhaltsanalyse. In: Baur, N.; Blasius, J. (Hrsg.): *Handbuch Methoden der empirischen Sozialforschung*, Wiesbaden, S. 633–648
- Mayring, P. (2019): Qualitative Inhaltsanalyse – Abgrenzungen, Spielarten, Weiterentwicklungen. *Forum Qualitative Sozialforschung* 20 (3), S. 1-15
- Mayring, P. (2015): Qualitative Inhaltsanalyse. Grundlagen und Techniken. Beltz Pädagogik. 12. Aufl. Beltz, Weinheim
- McAfee, A.; Brynjolfsson, E. (2012): Big data. The management revolution. *Harvard Business Review* October, S. 59-68
- McChrystal, S. A.; Collins, T.; Silverman, D.; Fussell, C. (2015): Team of teams. New rules of engagement for a complex world. Portfolio Penguin, London
- Mehanna, W.; Tatzel, J.; Vogel, P. (2016): Business Analytics im Controlling - Fünf Anwendungsfelder. *Controlling Heft 8-9* (28), S. 502–508
- Metz, C. (2022): The New Chatbots Could Change the World. Can You Trust Them? <https://www.nytimes.com/2022/12/10/technology/ai-chat-bot-chatgpt.html>, 14.06.2023
- Meulen, R. v.; McCall, T. (2018): Gartner Survey Shows Organizations Are Slow to Advance in Data and Analytics. <https://www.gartner.com/en/newsroom/press-releases/2018-02-05-gartner-survey-shows-organizations-are-slow-to-advance-in-data-and-analytics>, 16.10.2020

- Miller, H. G.; Mork, P. (2013): From Data to Decisions: A Value Chain for Big Data. IT Professional 15 (1), S. 57–59
- Mohamad, A. H.; Al-Saiyd, N. (2010): A framework for expert knowledge acquisition. International Journal of Computer Science and Network Security (IJCSNS) 10 (11), S. 145–151
- Mohanna, G.; Shaw, M. (2019): How to Deploy Your Data Science Team Across the Business. <https://www.informationweek.com/how-to-deploy-your-data-science-team-across-the-business/a/d-id/1334656?>, 11.01.2021
- Möller, A.; Hedemann, J. (2018): Nutzung von e!Sankey Calc als Modellierungswerkzeug. 9. BUIS-Tage. Otto-von-Guericke-Universität Magdeburg. 11.- 12.05.2017
- Morris, P. W. G.; Hough, G. H. (1987): The anatomy of major projects. A study of the reality of project management. Wiley, Chichester
- Mörth, O.; Emmanouilidis, C.; Hafner, N.; Schadler, M. (2020): Cyber-physical systems for performance monitoring in production intralogistics. Computers & Industrial Engineering 142, S. 1-10
- Nadali, A.; Kakhky, E. N.; Nosratabadi, H. E. (2011): Evaluating the success level of data mining projects based on CRISP-DM methodology by a Fuzzy expert system. 3rd International Conference on Electronics Computer Technology (ICECT). Kanyakumari. 08. - 10.04.2011
- Nagel, M.; Mieke, C.; Teuber, S. (2020): Methodenhandbuch der Betriebswirtschaft. UTB Bd. 8564. 2. Aufl. UVK Verlag; UTB, München
- Nagle, T.; Sammon, D. (2017): The Data Value Map: A framework for developing shared understanding on data initiatives. In: European Conference on Information Systems (ECIS). ECIS, S. 1439–1452
- Neifer, T.; Lawo, D.; Esan, M. (2021): Data Science Canvas: Evaluation of a Tool to Manage Data Science Projects. 54th Hawaii International Conference on System Sciences (HICSS). Honolulu, Hawaii. 05.- 08.01.2021
- Neifer, T.; Lawo, D.; Bossauer, P.; Esau, M.; Jerofejev, A.-M. (2020): Data Storytelling als kritischer Erfolgsfaktor von Data Science. HMD Praxis der Wirtschaftsinformatik 57 (5), S. 1033–1046
- Nestler, A. (2003): Die Bewertung von immateriellen Vermögensgegenständen. <https://www.iww.de/bbp/archiv/bilanzierung-die-bewertung-von-immateriellen-vermoegensgegenstaenden-f33778>, 17.06.2020

- Nitzsch, R. von; Methling, F. (2019): Zum Praktischen Anwendungsnutzen Der Entscheidungstheorie. SSRN Electronic Journal 2019, S. 1-10
- Noy, N. F.; McGuinness, D. L. (2001): Ontology Development 101: A Guide to Creating Your First Ontology.
https://protege.stanford.edu/publications/ontology_development/ontology101.pdf, 18.07.2022
- OpenAI (2023): Chatverlauf ChatGPT. <https://chat.openai.com/>, 08.06.2023
- OpenAI (2022): ChatGPT. <https://chatgptonline.net/>, 11.06.2023
- Optis, M.; Kumler, A.; Brodie, J.; Miles, T. (2021): Quantifying sensitivity in numerical weather prediction-modeled offshore wind speeds through an ensemble modeling approach. *Wind Energy* 24 (9), S. 957–973
- Ørsted (2017): Vindeby geht in Rente. <https://energiewinde.orsted.de/energiewirtschaft/vindeby-offshore-windpark-abriss-rueckbau>, 16.12.2022
- Österle, H.; Becker, J.; Frank, U.; Hess, T.; Karagiannis, D.; Krcmar, H.; Loos, P.; Mertens, P.; Oberweis, A.; Sinz, E. J. (2010): Memorandum zur gestaltungsorientierten Wirtschaftsinformatik. *Schmalenbachs Zeitschrift für betriebswirtschaftliche Forschung* 62 (6), S. 664–672
- Osterwalder, A.; Pigneur, Y.; Clark, T. (2010): *Business model generation. A handbook for visionaries, game changers, and challengers.* John Wiley & Sons, Hoboken
- Osterwalder, A. (2004): *The Business Model ontology a proposition in a design science approach.* Dissertation, 'Ecole des Hautes Etudes Commerciales de l'Université de Lausanne
- Oswald, K.; Dringenberg, H.; Ledermann, C.; Rofner, A.; Schiefer, E.; Simons, E.; Witzemann, M. (2011): *Reaching Peak O&M Performance in Power Generation.*
<https://www.scribd.com/document/413528650/Reaching-Peak-OM-Performance-in-Power-Generation>, 05.02.2024
- Ozdemir, S.; Kakade, S. (2018): *Principles of data science. A beginner's guide to statistical techniques and theory to build effective data-driven applications.* Packt, Birmingham, UK
- Patil, D. J. (2019): *Building data science teams. The Skills, Tools, and Perspectives Behind Great Data Science Groups.* O'Reilly Media; O'Reilly, Sebastopol
- Peppers, K.; Tuunanen, T.; Rothenberger, M. A.; Chatterjee, S. (2007): A Design Science Research Methodology for Information Systems Research. *JMIS* 24 (3), S. 45–77
- Perez, C. E. (2017): *Introducing the Deep Learning AI Canvas.*
<https://medium.com/intuitionmachine/introducing-the-deep-learning-canvas-a2e80a998f11>, 25.11.2022

- Pfaffel, S.; Faulstich, S.; Rohrig, K. (2020): Considering Uncertainties of Key Performance Indicators in Wind Turbine Operation. *Applied Sciences* 10 (3), S. 898-915
- Phillips, J.; Fitch-Roy, O.; Reynolds, P.; Gardner, P. (2013): A guide to UK offshore wind operations and maintenance.
https://www.researchgate.net/publication/327721479_A_guide_to_UK_offshore_wind_operations_and_maintenance, 30.01.2024
- Plotly Technologies Inc. (2015): Low-Code Python Data Apps. <https://plotly.com/>, 08.07.2023
- Practical Application Company (2000): Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining 27.– 31.08.1998 in New York.
<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.198.5133&rep=rep1&type=pdf>, 15.08.2020
- Prexl, L. (2019): *Mit digitalen Quellen arbeiten*. 3. Aufl. UTB GmbH; Schöningh, Stuttgart
- Project Management Institute (2013): *A guide to the project management body of knowledge (PMBOK guide)*. Project Management Institute Inc, Newtown Square Pennsylvania
- Provost, F.; Fawcett, T. (2013): Data Science and its Relationship to Big Data and Data-Driven Decision Making. *Big data* 1 (1), S. 51–59
- QlikTech International AB (2019): 3 Steps to a stronger KPI strategy. Building the approach that boosts competitive edge. <https://www.qlik.com/us/-/media/files/resource-library/global-us/register/whitepapers/wp-3-steps-to-a-stronger-kpi-strategy-en.pdf>, 10.06.2020
- Roland Berger (2013): *Offshore Wind Towards 2020. On the pathway to cost competitiveness*.
https://www.rolandberger.com/media/pdf/Roland_Berger_Offshore_Wind_Study_20130506.pdf, 02.07.2018
- Rothstein, D.; Santana, L. (2011): Teaching Students to Ask Their Own Questions. One small change can yield big results. https://www.hepg.org/hel-home/issues/27_5/helarticle/teaching-students-to-ask-their-own-questions_507, 24.05.2021
- Rüdiger, A.; Litzel, N. (2015): *Wie man Daten in Geld bewertet. Finanzwert von Daten*.
<https://www.bigdata-insider.de/wie-man-daten-in-geld-bewertet-a-511051/>, 17.06.2020
- Sandvig, C.; Hamilton, K.; Karahalios, K.; Langbort, C. (2014): “Data and Discrimination: Converting Critical Concerns into Productive Inquiry,” a preconference at the 64th Annual Meeting of the International Communication Association. Mai 22, 2014 in Seattle, WA, USA.
<http://social.cs.uiuc.edu/papers/pdfs/ICA2014-Sandvig.pdf>, 04.01.2021

- Santos, N. A. d. L. F. F. d. (2020): An agile process for modeling logical architectures: demonstration cases from large-scale software projects. Dissertation, Universität Minho
- Scheu, M. N.; Trempe, L.; Smolka, U.; Kolios, A.; Brennan, F. (2019): A systematic Failure Mode Effects and Criticality Analysis for offshore wind turbine systems towards integrated condition based maintenance strategies. *Ocean Engineering* 176, S. 118–133
- Schmarzo, B. (2016): Determining the Economic Value of Data.
https://infocus.delltechnologies.com/william_schmarzo/determining-economic-value-data/, 12.06.2020
- Schmidt, M. (2008): The Sankey Diagram in Energy and Material Flow Management. *Journal of Industrial Ecology* 12 (1), S. 82–94
- Schwabish, J. A. (2021): Better data visualizations. A guide for scholars, researchers, and wonks. Columbia University Press, New York
- Seiner, R. S. (2014): Non-Invasive Data Governance. Technics Publications LLC, Sedona
- Seliya, N.; LeBlanc, H.; Hylton, J.; Youssfi, Z.; Schweinefuss, M. (2019): Data-Driven Investigation of Curiosity in Student Text Responses. 2019 ASEE Annual Conference & Exposition. Tampa, Florida. 16.- 19.06.2019
- Seyr, H.; Muskulus, M. (2019): Decision Support Models for Operations and Maintenance for Offshore Wind Farms: A Review. *Applied Sciences* 9 (2), S. 278-308
- Shneiderman, B. (1996): The eyes have it: a task by data type taxonomy for information visualizations. 1996 IEEE Symposium on Visual Languages. Boulder. 03.- 06.09.1996
- Siemens AG (2014): The new standard for offshore. Siemens D6 platform – 6.0-MW direct drive wind turbine. <https://assets.new.siemens.com/siemens/assets/public.1541966686.1c690d9444b15f1a542d0e3166f43a90814743f2.d6-offshore-brochure-en.pdf>, 01.04.2022
- Skiena, S. S. (2017): The Data Science Design Manual. Springer International Publishing, Cham
- Sovacool, B. K.; Enevoldsen, P. (2015): One style to build them all: Corporate culture and innovation in the offshore wind industry. *Corporate culture and innovation in the offshore wind industry. Energy Policy* 86, S. 402–415
- Sperstad, I. B.; Stålhane, M.; Dinwoodie, I.; Endrerud, O.-E. V.; Martin, R.; Warner, E. (2017): Testing the robustness of optimal access vessel fleet selection for operation and maintenance of offshore wind farms. *Ocean Engineering* 145, S. 334–343
- Springer, F. (2017): Echtzeit- und Ereignisorientierung in Kreditinstituten. Springer, Wiesbaden

- Stahlmann, A.; Schlurmann, T. (2012): Kolkbildung an komplexen Gründungsstrukturen für Offshore-Windenergieanlagen. *Bautechnik* 89 (5), S. 293–300
- Stiesdal, H.; Madsen, P. H. (2005): *Design for Reliability*. Copenhagen Offshore Wind (COW). Copenhagen. 26.- 28.10.2005
- Stockinger, K.; Stadelmann, T.; Ruckstuhl, A. (2016): Data Scientist als Beruf. In: Fasel, D.; Meier, A. (Hrsg.): *Big Data*. Edition HMD, Wiesbaden, S. 59–81
- Stuckenschmidt, H. (2011): *Ontologien. Konzepte, Technologien und Anwendungen*. Informatik im Fokus. 2. Aufl. Springer, Berlin/Heidelberg
- Student, D. (2021): Seeschlacht zwischen Stromriesen und Ölkonzernen. <https://www.managermagazin.de/unternehmen/energie/orsted-vattenfall-rwe-shell-exxon-die-seeschlacht-um-den-offshore-windmarkt-a-bf4b6f95-0002-0001-0000-000177930927>, 04.06.2023
- Taylor, D. (2013): *Predictive Analysis Enables Operational Insights*. <https://blogs.sap.com/2013/03/05/predictive-analysis-enables-operational-insights/>, 22.02.2021
- Tempich, C.; Rieger, V. (2007): Data-centric business models Leveraging the hidden treasures of the telecom industry. https://www.researchgate.net/publication/315842565_Data-centric_business_models_Leveraging_the_hidden_treasures_of_the_telecom_industry, 30.01.2024
- Tomanek, D. P.; Schröder, J. (2018): *Value Added Heat Map*. Springer, Wiesbaden
- Vasandani, J. (2019): A Data Science Workflow Canvas to Kickstart Your Projects. Use this guide to help you complete your data science projects. <https://towardsdatascience.com/a-data-science-workflow-canvas-to-kickstart-your-projects-db62556be4d0>, 18.12.2022
- Venera Geambasu, C. (2012): BPMN vs. UML Activity Diagram for business process modelling. *Journal of Accounting and Management Information Systems* 11, S. 637–651
- Verbeke, W.; Baesens, B.; Bravo, C. (2017): *Profit-Driven Business Analytics. A Practitioner's Guide to Transforming Big Data into Added Value*. Wiley & SAS business series. Wiley, Hoboken, New Jersey
- Verhulst, S. G. (2020): *Unlock the Hidden Value of Your Data*. <https://hbr.org/2020/05/unlock-the-hidden-value-of-your-data>, 11.07.2020
- Vollmuth, J. H.; Zwettler, R. (2015): *Kennzahlen*. Haufe TaschenGuide Bd. 186. 3. Aufl. Haufe, Stuttgart
- Wang, R. Y.; Strong, D. M. (1996): Beyond Accuracy: What Data Quality Means to Data Consumers. *Journal of Management Information Systems* 12 (4), S. 5–33

- Wegener, J., Harms, L., Hartinger, M., Findeisen, A. (Hrsg.) (2016): Praxishandbuch Schnittstellenmanagement Offshore Wind. EEHH, Hamburg
- Wilde, T.; Hess, T. (2007): Forschungsmethoden der Wirtschaftsinformatik. Wirtschaftsinformatik 49 (4), S. 280–287
- Wilde, T.; Hess, T. (2006): Methodenspektrum der Wirtschaftsinformatik. Überblick und Portfoliobildung. https://epub.ub.uni-muenchen.de/14146/1/hess_14146.pdf, 05.02.2022
- Wirth, R.; Hipp, J. (2000): CRISP-DM: Towards a Standard Process Model for Data Mining. Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining. New York. 27.– 31.08.1998
- Wolken-Möhlmann, G.; Bendlin, D.; Buschmann, J.; Wiggert, M. (2016): Project Schedule Assessment with a Focus on Different Input Weather Data Sources. Energy Procedia 94, S. 517–522
- Wöltje, J. (Hrsg.) (2021): Schnelleinstieg Unternehmensbewertung und Finanzkennzahlen. 1. Aufl. Haufe Fachbuch. Haufe Lexware, Freiburg im Breisgau
- WorldGBC (2019): A sustainable built environment at the heart of Europe’s future. WorldGBC European Advocacy Manifesto June 2019. <https://worldgbc.org/news-media/worldgbc-europe-advocacy-manifesto>, 25.10.2021
- Wyss, M. (2019): Aufbau eines starken Data Science-Teams von Grund auf. <https://www.inwt-statistics.de/blog-artikel-lesen/aufbau-eines-starken-data-science-teams-von-grund-auf.html>, 12.07.2021
- Young, S. S. (2001): Computerized data acquisition and analysis for the life sciences. A hands-on guide. Cambridge University Press, Cambridge/New York
- Zaharia, M. (2020): How to empower data teams in 3 critical ways. <https://enterpriseproject.com/article/2020/12/data-science-3-ways-empower-teams>, 12.01.2021
- Zangemeister, C. (2014): Nutzwertanalyse in der Systemtechnik. Eine Methodik zur multidimensionalen Bewertung und Auswahl von Projektalternativen. 5. Aufl. Books on Demand, Norderstedt
- Zawadzki, J. (2019): Introducing the AI Project Canvas. <https://towardsdatascience.com/introducing-the-ai-project-canvas-e88e29eb7024>, 17.08.2022
- Zimmermann, H.-J.; Gutsche, L. (1991): Multi-Criteria Analyse. Einführung in die Theorie der Entscheidungen bei Mehrfachzielsetzungen. Heidelberger Lehrtexte Wirtschaftswissenschaften. Springer, Berlin, Heidelberg